

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Robi Turnar

Zagreb, 2013.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Dubravko Majetić, dipl. ing.

Student:

Robi Turnar

Zagreb, 2013.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se bližnjima na podršci, profesorima na stručnosti i kolegama na izazovu.

Posebna zahvala mentoru prof. dr. sc. Dubravku Majetiću na vodstvu i strpljenju tijekom izrade ovog rada.

Robi Turnar



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student: **ROBI TURNAR**

Mat. br.: 0035166014

Naslov rada na hrvatskom jeziku: **Neuronska mreža u identifikaciji laboratorijskog modela regulacije nivoa tekućine**

Naslov rada na engleskom jeziku: **Neural Network in Identification of Laboratory Setup for Water Level Control**

Opis zadatka:

Korištenjem statičke umjetne neuronske mreže, potrebno je izvršiti identifikaciju laboratorijskog modela regulacije visine tekućine u otvorenom spremniku. Matematički model treba identificirati regulacijskom petljom realiziranom promjenom snage vodene pumpe. Potom je potrebno model identificiran umjetnom neuronskom mrežom usporediti s modelom identificiranim klasičnim postupkom identifikacije.

U radu je potrebno načiniti slijedeće:

1. Izvesti algoritam učenja statičke unaprijedne neuronske mreže s povratnim prostiranjem pogreške (EBP).
2. U klasični EBP algoritam uvesti metodu momentuma prvog i drugog reda.
3. Neuronskom mrežom identificirati regulacijsku stazu u kojoj se regulacija nivoa odvija vodenom pumpom.
4. Usporediti klasično identificirani model s modelom identificiranim umjetnom neuronskom mrežom.
5. Izvesti zaključke rada.

Zadatak zadan:

6. prosinca 2012.

Rok predaje rada:

7. veljače 2013.

Predvideni datum obrane:

13. - 15. veljače 2013.

Zadatak zadao:

Prof.dr.sc. Dubravko Majetić

Predsjednik Povjerenstva:

Prof. dr. sc. Franjo Cajner

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS OZNAKA	VI
SAŽETAK.....	VIII
SUMMARY	IX
1. UVOD.....	1
2. OPIS MAKETE.....	2
2.1. Sastavni dijelovi.....	2
2.2. Upravljanje stanjima elemenata i očitavanje visine sa senzora	5
3. SNIMANJE I ANALIZA MJERENJA NA MODELU.....	7
3.1. Vrste staza	7
3.1.1. Staza sa samim istjecanjem (staza I).....	7
3.1.2. Staza s pumpom (staza A).....	9
3.1.3. Staza s pumpom i poremećajnim ventilima (staza B).....	10
3.1.4. Staza s pumpom i troputnim ventilom (staza C).....	11
3.1.5. Staza s pumpom, poremećajnim ventilima i troputnim ventilom (staza K)	11
3.2. Analiza snimljenih podataka	11
3.2.1. Vremenska razlika između koraka	11
3.2.2. Kašnjenje odziva pumpe i poremećajnih ventila	12
3.3. Diskretizacija snimljenih mjerenja.....	14
4. IDENTIFIKACIJA SUSTAVA.....	17
4.1. Identifikacija stalnog istjecanja.....	18
4.2. Identifikacija istjecanja kroz poremećajne ventile	20
4.3. Identifikacija pumpe	23
4.4. Identifikacija troputnog ventila	26
5. IDENTIFIKACIJA SUSTAVA NEURONSKIM MREŽAMA.....	28
5.1. Statička unaprijedna neuronska mreža s povratnim prostiranjem pogreške (EBP) ...	28
5.2. Statička neuronska mreža s povratnom vezom (NNS1)	30
5.3. Statička neuronska mreža s povratnom vezom i integracijskom petljom (NNS2)	37

6. TESTIRANJE I USPOREDBA REZULTATA DOBIVENIH MATEMATIČKIM MODELOM I NEURONSKIM MREŽAMA	39
6.1. Staza s pumpom (staza A).....	39
6.1.1. Matematički model	39
6.1.2. Neuronske mreže.....	42
6.1.3. Međusobna usporedba modela.....	47
6.2. Staza s pumpom i poremećajnim ventilima (staza B).....	50
6.3. Staza s pumpom i troputnim ventilom (staza C).....	54
6.4. Staza s pumpom, poremećajnim ventilima i troputnim ventilom (staza K).....	58
7. ZAKLJUČAK.....	63
LITERATURA.....	64
PRILOZI.....	65

POPIS SLIKA

Slika 2.1	Skica makete sustava [1]	2
Slika 2.2	Pulsno-širinska modulacija (PWM)	3
Slika 2.3	Poprečni presjek troputnog ventila [1]	4
Slika 2.4	Izgled i shema senzora položaja	5
Slika 3.1	Prikaz promjene visine tekućine kod istjecanja	8
Slika 3.2	Promjena visina uz mijenjanje snage pumpe kroz vrijeme	10
Slika 3.3	Vremenska razlika između koraka	12
Slika 3.4	Brzina promjene visine u ovisnosti o snazi pumpe	13
Slika 3.5	Brzina promjene visine u ovisnosti o snazi pumpe i stanju poremećajnih ventila	14
Slika 3.6	Prikaz interpoliranih točaka uz originalno kašnjenje snage pumpe	15
Slika 3.7	Prikaz interpoliranih točaka uz dodatno kašnjenje snage pumpe	16
Slika 4.1	Detaljniji prikaz točaka kod samog istjecanja	19
Slika 4.2	Podaci i funkcija glavnog istjecanja	20
Slika 4.3	Podaci i funkcija istjecanja desnog poremećajnog ventila	22
Slika 4.4	Podaci i funkcija istjecanja lijevog poremećajnog ventila	22
Slika 4.5	Dobivanje podataka o brzini promjene visine s obzirom na snagu pumpe	23
Slika 4.6	Podaci o brzini promjene visine uslijed djelovanja pumpe	24
Slika 4.7	Podaci i estimirana funkcija utjecanja uslijed djelovanja pumpe	25
Slika 4.8	Podaci i estimirana funkcija redukcije utjecanja uslijed zatvorenosti troputnog ventila	26
Slika 5.1	Statička unaprijedna neuronska mreža	29
Slika 5.2	Aktivacijska funkcija skrivenog sloja neuronske mreže	30
Slika 5.3	Statička neuronska mreža s povratnom vezom (NNS1)	31
Slika 5.4	Statička neuronska mreža s povratnom vezom i integracijskom petljom (NNS2)	38
Slika 6.1	NRMS matematičkog modela na stazi A	40
Slika 6.2	Maksimalna razlika visine matematičkog modela i staze A	41
Slika 6.3	Prikaz najveće greške između matematičkog modela i staze A	41
Slika 6.4	Prikaz najmanje greške između matematičkog modela i staze A	42
Slika 6.5	Karakteristični pad NRMS-a kod učenja po skupu uzoraka	44
Slika 6.6	Prikaz najveće greške između neuronskih mreža i staze A za $\Delta T = 0,1$ s	45

Slika 6.7	Prikaz najveće greške između neuronskih mreža i staze A za $\Delta T=0,02$ s	46
Slika 6.8	NRMS neuronske mreže NNS1 na stazi A za $\Delta T=0,1$ s	48
Slika 6.9	NRMS neuronske mreže NNS2 na stazi A za $\Delta T=0,1$ s	49
Slika 6.10	Shematski prikaz matematičkog modela staze A	49
Slika 6.11	Shematski prikaz neuronskih mreža staze A	49
Slika 6.12	NRMS modela i neuronskih mreža staze B za $\Delta T=0,1$ s	51
Slika 6.13	Prikaz najveće greške između neuronskih mreža i staze B	52
Slika 6.14	Shematski prikaz matematičkog modela staze B	53
Slika 6.15	Shematski prikaz neuronske mreže NNS1 staze B	53
Slika 6.16	Shematski prikaz neuronske mreže NNS2 staze B	53
Slika 6.17	NRMS matematičkog modela staze C za $\Delta T=0,1$ s	55
Slika 6.18	NRMS neuronske mreže NNS1 na stazi C za $\Delta T=0,1$ s	55
Slika 6.19	NRMS neuronske mreže NNS2 na stazi C za $\Delta T=0,1$ s	56
Slika 6.20	Prikaz najveće greške između neuronskih mreža i staze C	57
Slika 6.21	Shematski prikaz matematičkog modela staze C	57
Slika 6.22	Shematski prikaz neuronske mreže NNS1 staze C	58
Slika 6.23	Shematski prikaz neuronske mreže NNS2 staze C	58
Slika 6.24	NRMS matematičkog modela i neuronskih mreža staze K za $\Delta T=0,1$ s	60
Slika 6.25	Prikaz greške modela i mreža staze K na uzorku broj 1	61
Slika 6.26	Prikaz greške modela i mreža staze K na uzorku broj 20	61
Slika 6.27	Shematski prikaz matematičkog modela staze K	62
Slika 6.28	Shematski prikaz neuronske mreže NNS1 staze K	62
Slika 6.29	Shematski prikaz neuronske mreže NNS2 staze K	62

POPIS TABLICA

Tablica 2.1 Instrukcije u MATLAB-u za upravljanje ili očitavanje stanja elemenata.....	5
Tablica 6.1 Utjecaj koraka diskretizacije na grešku matematičkog modela	40
Tablica 6.2 Rezultati učenja neuronske mreže NNS1 na uzorku broj 81 staze A.....	43
Tablica 6.3 Rezultati učenja neuronske mreže NNS2 na uzorku broj 81 staze A.....	43
Tablica 6.4 Rezultati učenja neuronskih mreža po skupu svih uzoraka staze A.....	45
Tablica 6.5 Najbolji rezultati modela i mreža staze A s korakom diskretizacije 0,1 s.....	47
Tablica 6.6 Najbolji rezultati modela i mreža staze B s korakom diskretizacije 0,1 s.....	50
Tablica 6.7 Najbolji rezultati modela i mreža staze C s korakom diskretizacije 0,1 s.....	54
Tablica 6.8 Najbolji rezultati modela i mreža staze K s korakom diskretizacije 0,1 s.....	59

POPIS OZNAKA

Oznaka	Jedinica	Opis
D	/	Vektor stvarne visine staze
D_h	mm/s	Brzina promjene visine
D_{hi}	mm/s	Brzina promjene visine uslijed glavnog istjecanja
D_{hid}	mm/s	Brzina promjene visine uslijed istjecanja kroz desni ventil
D_{hil}	mm/s	Brzina promjene visine uslijed istjecanja kroz lijevi ventil
D_{hp}	mm/s	Brzina promjene visine uslijed pumpe
D_{hu}	mm/s	Brzina promjene visine uslijed utjecanja kroz ulazni vod
dH_{MM}	mm	Promjena visine dobivena matematičkim modelom
dH_{NN}	mm	Promjena visine dobivena neuronskom mrežom
dt	s	Korak diskretizacije
E	/	Suma kvadratne pogreške
H	mm	Visina
H_{NN}	mm	Visina dobivena neuronskom mrežom
H_p	mm	Početna visina
k_i, h_i	/	Koeficijenti funkcije glavnog istjecanja
k_{id}, h_{id}	/	Koeficijenti funkcije istjecanja kroz desni poremećajni ventil
k_{il}, h_{il}	/	Koeficijenti funkcije istjecanja kroz lijevi poremećajni ventil
K_p	/	Vektor koeficijenata funkcije utjecanja pumpe
K_r	/	Vektor koeficijenata funkcije redukcije utjecanja pumpe
N_h	/	Broj neurona skrivenog sloja neuronske mreže
N_{par}	/	Ukupni broj parametara neuronske mreže
N_z	/	Broj ulaza neuronske mreže
$NRMS$	/	Normalizirani korijen srednje kvadratne pogreške
$NRMS$	/	Prosječna vrijednost $NRMS$ -a
net_H	/	Vektor suma skrivenog sloja neuronske mreže
net_O	/	Suma izlaznog sloja neuronske mreže
P_n	%	Postotak snage u n -tom koraku
PVD_n	/	Stanje desnog poremećajnog ventila u n -tom koraku
PVL_n	/	Stanje lijevog poremećajnog ventila u n -tom koraku
R	/	Redukcija utjecanja uslijed zatvorenosti troputnog ventila
VDH	mm/s	Vektor brzina promjene visine
VH	mm	Vektor visina
VP	%	Vektor postotaka snage
$VPVD$	/	Vektor stanja desnog poremećajnog ventila
$VPVL$	/	Vektor stanja lijevog poremećajnog ventila

\mathbf{VT}	s	Vektor vremena
TV	%	Položaj troputnog ventila
\mathbf{v}	/	Matrica težina skrivenog sloja neuronske mreže
\mathbf{v}_n	/	Matrica težina skrivenog sloja nakon učenja
\mathbf{v}_s	/	Matrica težina skrivenog sloja u prethodnom koraku (n-1)
\mathbf{v}_{ss}	/	Matrica težina skrivenog sloja u prethodnom koraku (n-2)
\mathbf{w}	/	Vektor težina izlaznog sloja neuronske mreže
\mathbf{w}_n	/	Vektor težina izlaznog sloja nakon učenja
\mathbf{w}_s	/	Vektor težina izlaznog sloja u prethodnom koraku (n-1)
\mathbf{w}_{ss}	/	Vektor težina izlaznog sloja u prethodnom koraku (n-2)
\mathbf{Z}	/	Matrica ulaznih podataka neuronske mreže
α	/	Koeficijent momentuma prvog reda
β	/	Koeficijent momentuma drugog reda
γ_J	/	Prijenosna funkcija skrivenog sloja neuronske mreže
η	/	Brzina učenja neuronske mreže
$\nabla E_v (\mathbf{G}_v)$	/	Matrica gradijenata pogrešaka težina skrivenog sloja
$\nabla E_w (\mathbf{G}_w)$	/	Vektor gradijenata pogrešaka težina izlaznog sloja

SAŽETAK

U ovom diplomskom radu opisana je identifikacija laboratorijskog modela regulacije visine tekućine u otvorenom spremniku. Pritom su korištena dva različita modela. Matematički model identificiran je klasičnim postupkom identifikacije, dok je drugi model identificiran umjetnom neuronskom mrežom.

U prvom poglavlju opisan je laboratorijski model koji se sastoji od četiri aktivna elementa i jednog senzora stanja. Aktivni elementi koji se promatraju su vodena pumpa, troputni ventil i dva poremećajna ventila. Senzor stanja je senzor koji mjeri visinu tekućine u menzuri.

Snimanje podataka s laboratorijskog modela opisano je u drugom poglavlju. Pritom je laboratorijski model rastavljen na pet različitih staza. Podaci su snimljeni za svaku stazu posebno. Dobiveni su podaci dodatno analizirani kako bi se otklonile moguće pogreške.

U trećem poglavlju napravljena je identifikacija za svaki aktivni element posebno. Povezivanjem estimiranih elemenata dobiveni su matematički modeli svih staza.

Opis neuronskih mreža dan je u četvrtom poglavlju. Pritom su iz osnovnog oblika statičke neuronske mreže dobivene dvije različite neuronske mreže za identifikaciju modela.

U petom poglavlju opisana je usporedba matematičkog modela i neuronskih mreža. Usporedba je napravljena za svaku stazu posebno kako bi se mogao vidjeti utjecaj pojedinih elemenata na samu identifikaciju.

Ključne riječi: identifikacija, neuronske mreže, matematički model, laboratorijski model

SUMMARY

The aim of this diploma thesis is to describe the identification of a laboratory setup for water level regulation in an open tank. Two different models were used. The mathematical model was identified by using the classic identification procedure, while the other model was identified by using an artificial neural network.

The laboratory model which consists of four active elements and one level sensor is described in the first chapter. The studied active elements are a water pump, three-way valve and two disturbance valves. A level sensor is a sensor for measuring the liquid level in the measuring cylinder.

Data recording from the laboratory setup is described in the second chapter. The laboratory model is divided into four different control paths. Data were recorded for each control path separately. The obtained data were additionally analysed in order to remove possible errors.

In the third chapter, each active element is separately identified. Mathematical models of all control paths were calculated by connecting the estimated elements.

A description of neural networks is given in the fourth chapter. Two different neural networks for model identification were obtained based on the basic form of the static neural network.

A description of the comparison of the mathematical model and neural networks is given in the fifth chapter. The comparison was carried out for each control path separately in order to present the effect of individual elements on the classification.

Key words: identification, neural networks, mathematical model, laboratory setup

1. UVOD

Za opisivanje pojava u prirodi čovjek odavno primjenjuje matematiku. Većina tih pojava slijedi neke zakonitosti usprkos prividnom stanju kaosa. Za postizanje prednosti pred prirodom bitno je povezati činjenice kako bi se mogla napraviti predikcija budućih stanja. Najbolji primjer toga je vremenska prognoza. Čovjek je od davnina počeo primjećivati određene zakonitosti pri promjeni vremena. Danas se za predikciju vremena koriste složeni matematički modeli koji prema podacima starim i do pedeset godina pokušavaju što je točnije simulirati pojave u prirodi. Razvitkom računala počele su se primjenjivati i neuronske mreže. Neuronske mreže za razliku od matematičkog modela ne traže od korisnika detaljno poznavanje ponašanja sustava. Za njih je potreban dobar izbor faktora koji utječu na ponašanje te dovoljno velik uzorak prema kojem mreže uče. Glavni faktori koji utječu na promjenu vremena su najčešće temperatura, tlak, vjetar i količina padalina. Prema tim prikupljenim podacima mreža uči, nakon čega može simulacijom dati prognozu vremena za određeno razdoblje. Pritom se jedna složena neuronska mreža može podijeliti na više manjih. Primjer toga bilo bi kreiranje neuronskih mreža za svaki mjesec u godini, umjesto jedne složene mreže koja bi kao faktor u obzir morala uzimati i trenutni mjesec.

Neuronske mreže imaju sve veću primjenu i u tehničkim sustavima, odnosno sustavima koje je stvorio čovjek. U tehničkim sustavima također postoje određene zakonitosti koje je moguće opisati matematičkim modelom ili naučiti neuronskim mrežama. Neuronske mreže se pritom mogu podijeliti na mreže koje uče na temelju podataka simuliranih na računalu te na temelju podataka dobivenih očitanjem stanja stvarnih sustava. Razlike kod tih podataka su najčešće sustavne pogreške. Slučajne pogreške moguće je simulirati na računalu, dok je sustavne pogreške često teško primijetiti sve dok se stvarni sustav ne pokuša modelirati matematički ili učenjem neuronskih mreža. Upravo sustavne pogreške rade najviše problema kod modeliranja sustava, stoga ih je za uspješnost modeliranja bitno prepoznati i po mogućnosti ukloniti.


Najčešće pitanje koje se postavlja kod modeliranja je razlika uspješnosti između matematičkog modela i neuronskih mreža. Zato je u ovom radu napravljena njihova direktna usporedba. Kao promatrani sustav izabran je laboratorijski model otvorenog spremnika, gdje se mogu promatrati razni utjecaji elemenata od kojih je model sastavljen. Ponašanje tih elemenata pokušat će se modelirati matematički i neuronskim mrežama.

2. OPIS MAKETE

Maketa na kojoj se promatra ponašanje sustava sastavljena je od više dijelova. Dijelovi makete mogu se ugrubo podijeliti na sastavne dijelove koji sudjeluju u samom procesu i elektroniku koja upravlja tim dijelovima.

2.1. Sastavni dijelovi

Cijela maketa i njezini sastavni dijelovi prikazani su na slici [Slika 2.1].



Slika 2.1 Skica makete sustava [1]


Sastavni dijelovi pričvršćeni su na zatvorenu kutiju od pleksiglasa. Kutija je podijeljena na tri dijela. U desnom, najvećem odjeljku, nalazi se tekućina, u ovom primjeru destilirana voda. U

lijevom odjeljku nalazi se pumpa, dok je središnji prazan. Na gornju plohu kutije pričvršćeni su ostali dijelovi.

1. Ventili (lijevi i desni)
2. Menzura sa otvorom na dnu
3. Pumpa
4. Troputni ventil s koračnim motorom
5. Senzor položaja
6. Upravljačka elektronika
7. Spremnik s vodom
8. Cijev skretanja vode u spremnik
9. Cijev skretanja vode u menzuru
10. Cijev dovoda vode u pumpu
11. Cijev dovoda vode iz pumpe u troputni ventil

Menzura je okruglog presjeka i napravljena od prozirne plastike. Na dnu menzure nalazi se otvor kroz koji voda u menzuri istječe u spremnik. Na lijevoj i desnoj strani menzure nalaze se otvori i cijevi koje vode do ventila. Ventili su elektromagnetski i posjeduju dva moguća stanja, a u normalnom položaju su zatvoreni. Kada se na njih dovede napon od 24 V, ventili se otvaraju pa voda iz menzure kroz njih istječe u spremnik.


S druge strane nalazi se pumpa za vodu koja inače služi za pranje vjetrobranskog stakla kod kamiona marke Iveco. Ona također radi na naponu od 24 V, a njezina brzina kontrolira se pomoću pulsno-širinske modulacije (engl. pulse-width modulation - PWM).



Slika 2.2 Pulsno-širinska modulacija (PWM)

Umjesto linearnog smanjivanja napona, kod pulsno-širinske modulacije napon se dovodi u svojem maksimalnom iznosu, ali skraćenog trajanja u obliku pulsova. To se može najlakše prikazati slikom [Slika 2.2]. Iz slike se vidi kako se na pumpu šalju samo dvije granične vrijednosti napona. Iscrtna linija prikazuje srednju vrijednost napona koja predstavlja odabrani postotak snage pumpe.


Voda iz pumpe ulazi u troputni ventil. U troputnom ventilu voda se grana u dva smjera, prema menzuri i prema spremniku. Na slici [Slika 2.3] prikazan je njegov poprečni presjek.



Slika 2.3 Poprečni presjek troputnog ventila [1]

Iz prikazane strukture vidi se kako troputni ventil ne prigušuje protok pumpe. Pomicanjem klipa određuje se protok vode koji ide u menzuru i protok vode koji se vraća u spremnik. Pomicanje klipa realizirano je koračnim motorom. Položaj klipa zadaje se u postocima, pri čemu nula predstavlja krajnji lijevi položaj, odnosno slučaj kada sva voda iz pumpe ide prema menzuri.

Jedini senzor koji postoji na maketi je senzor položaja prikazan na slici [Slika 2.4]. Senzor je postavljen okomito u menzuru, a na njegov pomični magnet pričvršćen je plovak. Mijenjanjem razine vode u menzuri magnet se pomiče po vodilici senzora, a položaj magneta se očitava pomoću PWM signala. Senzor ima i mrtva područja na početku i kraju vodilice. Zbog toga se razina vode u menzuri može očitati samo sa vrijednosti visine od 80 do 320 mm. Pritom također treba biti oprezan da razina vode ne prijeđe 320 mm jer time voda dolazi do senzora, što može dovesti do njegovog oštećenja. Detaljnije specifikacije proizvođača dane su u prilogu [I].



Slika 2.4 Izgled i shema senzora položaja

2.2. Upravljanje stanjima elemenata i očitavanje visine sa senzora

Za upravljanje elemenata koristi se upravljačka elektronika koja je povezana sa svim aktivnim elementima na stazi. S druge strane povezana je sa računalom preko RS232 protokola. Slanje i primanje signala s upravljačke elektronike obavlja se pomoću skripti napisanih u MATLAB-u. U upravljačkoj elektronici definirane su instrukcije pomoću kojih se kontroliraju pojedini elementi i očitava visina sa senzora.

Tablica 2.1 Instrukcije u MATLAB-u za upravljanje ili očitavanje stanja elemenata

Element	Raspon vrijednosti (x)	Instrukcija	Funkcija u MATLAB-u
Snaga pumpe	0 do 100%	'px'	snaga.m
Položaj troputnog ventila	0 do 100%	'mx'	TV.m
Stanje desnog ventila	0 ili 1	'V2-' ili 'V2+'	PVD.m
Stanje lijevog ventila	0 ili 1	'V1-' ili 'V1+'	PVL.m
Položaj magneta senzora	$H=f(x)$	'h'	senzor.m

U priloženoj tablici [Tablica 2.1] navedene su instrukcije kojima se upravlja elementima na maketi. Pritom su prve četiri jednosmjerne i služe za upravljanje stanjima elemenata, dok nakon pete instrukcije elektronika šalje povratnu informaciju o položaju senzora (x). Visina vode dobiva se uvrštavanjem dobivene vrijednosti x u jednadžbu (2.1).

$$H = -0,0809 \cdot x + 366,5518 \quad (2.1)$$

Svaka se instrukcija radi preglednosti nalazi u zasebnoj funkciji u MATLAB-u.

Snaga pumpe regulira se pomoću PWM signala na način opisan prije. Upravljačka elektronika dobiva instrukciju s računala te na temelju željenog postotka snage pumpe generira odgovarajući PWM signal.

Položaj troputnog ventila postavlja se preko koračnog motora. Koračni motor povezan je s klipom troputnog ventila pomoću vijka M6. To znači da se za jedan puni okret motora klip pomakne za 0,8 mm. Koračni motor može zauzeti 200 pozicija u jednom okretu, što znači da je minimalni korak klipa jednak 0,004 mm. Nulta pozicija osigurava se pomoću mikroprekidača, dok se računanje broja okretaja iz željene pozicije klipa obavlja u samoj upravljačkoj elektronici.

Bočni ventili, koji se u nastavku zovu poremećajni, imaju samo dva stanja pa je njihovo upravljanje jednostavno. Ventili su u normalnom položaju zatvoreni, a kad se na njih pošalje napon od 24 V, oni se otvaraju.

3. SNIMANJE I ANALIZA MJERENJA NA MODELU

Sustav se sastoji od više elemenata, stoga ga je moguće promatrati na različite načine. Nekim se elementima može upravljati pa iz toga slijedi da se sustav može podijeliti na više različitih staza. Za snimanje podataka na pojedinoj stazi potrebno je generirati pripadajuće signale, pri čemu je korišteno nasumično generiranje kako bi se postigli što raznolikiji odzivi. Nakon što su odrađena mjerenja, snimljene je podatke potrebno proanalizirati i usporediti sa stvarnim ponašanjem staze. Mjerenja koja unose šumove ili imaju slučajne pogreške treba odbaciti i po potrebi ponoviti.

3.1. Vrste staza

Iz cijelog sustava moguće je izdvojiti više različitih staza. Vrsta staze govori o tome koji elementi utječu na trenutno promatrani sustav. Budući da se većinom elemenata u sustavu može upravljati, sustav je moguće podijeliti na pet različitih staza:

- a) staza sa samim istjecanjem (staza I)
- b) staza sa pumpom (staza A)
- c) staza sa pumpom i poremećajnim ventilima (staza B)
- d) staza sa pumpom i troputnim ventilom (staza C)
- e) staza sa pumpom, troputnim ventilom i poremećajnim ventilima (staza K).


Iz imena svake staze može se zaključiti koji elementi sustava su aktivni i čije se ponašanje promatra, a koji elementi ne mijenjaju stanja. Svaka staza objašnjena je zasebno i to po redoslijedu od jednostavnije do složenije. Svakoj stazi je također pridruženo slovo kako bi ih se lakše prepoznalo u izrađenim MATLAB skriptama.

3.1.1. Staza sa samim istjecanjem (staza I)

Staza na kojoj su svi aktivni elementi isključeni i ne sudjeluju u mjerenju je staza sa samim istjecanjem. Budući da se na glavno istjecanje ne može direktno utjecati, ono je prisutno u svakoj stazi. Snimanja obavljena na ovoj stazi prikazuju utjecaj visine tekućine na dinamiku istjecanja iz menzure.

Za snimanje podataka ove staze nije potrebno generirati signale jer su svi aktivni elementi na maketi isključeni. Budući da se promatra istjecanje, menzuru je najprije potrebno napuniti do

njene maksimalne dopuštene visine od 300 mm. Zatim je troputni ventil potrebno postaviti u zatvoren položaj kako tekućina ne bi istjecala kroz ulazni vod. Troputnom ventilu za to je potrebno neko vrijeme pa zbog toga početak snimanja počinje tek od približno 260 mm. Tijekom snimanja spremaju se podaci o trenutnoj visini i vremenu u pripadajuće vektore stanja VH i VT . Kada razina tekućine padne ispod minimalne vrijednosti, snimanje se prekida, a konačni vektori stanja spremaju u datoteku na disku. Za ilustraciju su slikom [Slika 3.1] pokazani podaci jednog karakterističnog postupka snimanja.



Slika 3.1 Prikaz promjene visine tekućine kod istjecanja

Staza sa samim istjecanjem može također biti promatrana zajedno s poremećajnim ventilima, budući da oni stvaraju samo dodatno istjecanje. U tom slučaju poremećajni ventili s vremenom ne mijenjaju stanje, već su stalno ili otvoreni ili zatvoreni. Taj prošireni oblik biti će potreban kasnije kod izrade matematičkog modela staze.

3.1.2. Staza s pumpom (staza A)

Staza s pumpom je staza u kojoj se regulacija razine tekućine u menzuri odvija snagom pumpe. Pritom poremećajni ventili i troputni ventil ne mijenjaju stanja. Snimanja dobivena na ovoj stazi pokazuju utjecaj snage pumpe na promjenu visine tekućine. U podacima je također uključeno i glavno istjecanje iz menzure.

Postupak snimanja razlikuje se od prethodnog, budući se obavlja od najniže do najviše razine tekućine. Potrebno je generirati nasumičan vektor snaga od 20% do 100%, preko kojeg će se tijekom vremena snimanja zadavati i mijenjati snaga pumpe.

Menzura se najprije napuni do početne vrijednosti visine od 90 mm, a to se postiže postavljanjem snage pumpe na 40%. Kada visina tekućine postigne tu vrijednost, očitava se visina te sprema u varijablu H_p . Zatim počinje snimanje podataka, gdje se u odgovarajuće vektore \mathbf{VP} , \mathbf{VH} i \mathbf{VT} spremaju trenutna snaga, visina i vrijeme. Korak uzorkovanja između dva očitavanja visine ne zadaje se ručno, nego ovisi o brzini reakcije sustava. Promjena snage pumpe u vremenu radi se na način da se za svakih 9 do 11 koraka, snaga postavlja na novu vrijednost koja je otprije nasumično generirana. Nakon što visina tekućine prijeđe vrijednost od 290 mm, snimanje se prekida.


Postotak snage pumpe, visina tekućine i vrijeme spremljeni su u svojim pripadajućim vektorima (3.1).

$$\begin{aligned}\mathbf{VP} &= [p_1 \ p_2 \ \dots \ p_n \ p_{n+1}] \\ \mathbf{VH} &= [100 \ h_1 \ h_2 \ \dots \ h_n] \\ \mathbf{VT} &= [0 \ t_1 \ t_2 \ \dots \ t_n]\end{aligned}\tag{3.1}$$

Iz vektora snage potrebno je ukloniti zadnji član jer je nakon postavljanja te snage mjerenje završilo. Iz vektora visine uklanja se prvi član koji je pokazivao od koje visine počinje mjerenje. Prava početna visina, u vremenu $t = 0$, spremljena je u varijabli H_p . Nakon sređivanja, novi vektori (3.2) i početna visina H_p spremaju se u datoteku.

$$\begin{aligned}\mathbf{VP} &= [p_1 \ p_2 \ \dots \ p_n] \\ \mathbf{VH} &= [h_1 \ h_2 \ \dots \ h_n] \\ \mathbf{VT} &= [0 \ t_1 \ t_2 \ \dots \ t_n]\end{aligned}\tag{3.2}$$

Na prikazanom primjeru jedne od snimaka [Slika 3.2], vidi se promjena visine tekućine kroz vrijeme uz promjenu snage pumpe svakih 11 koraka. U nultom koraku vidljive su točke početka mjerenja, visina tekućine na H_p i snaga pumpe 40% koja je bila aktivna do tog trenutka.



Slika 3.2 Promjena visina uz mijenjanje snage pumpe kroz vrijeme

3.1.3. Staza s pumpom i poremećajnim ventilima (staza B)

Sljedeća staza pored pumpe u obzir uzima i poremećajne ventile. Snimanje se obavlja na potpuno analogan način kao i u prethodnom slučaju, osim što ovdje postoji i utjecaj poremećajnih ventila na promjenu visine. Njihovo stanje generira se na sličan način kao i za snagu pumpe, osim što su njihovi vektori stanja unaprijed definirani za svaki korak vremena. Nakon završetka snimanja, pored osnovnih vektora stanja VP , VH i VT , prikazuju se i vektori stanja poremećajnih ventila (3.3).

$$\begin{aligned} VPVD &= [sd_1 \ sd_2 \ \dots \ sd_n] \\ VPVL &= [sl_1 \ sl_2 \ \dots \ sl_n] \end{aligned} \quad (3.3)$$

Svi navedeni vektori spremaju se u datoteku na disku.

3.1.4. Staza s pumpom i troputnim ventilom (staza C)

Zadnji aktivni element koji je preostao je troputni ventil. On će se najprije promatrati u stazi samo s pumpom. S obzirom na oblik sustava, troputni ventil bez pumpe zapravo nema smisla promatrati, budući da je njegov utjecaj uvjetovan aktivnim stanjem pumpe.

Snimanje na ovoj stazi još je bliže snimanju na stazi s pumpom jer u ovom slučaju nije potrebno generirati vektor stanja za troputni ventil. To je stoga što bi promjena stanja troputnog ventila uslijed načina rada upravljačke elektronike iziskivala preveliko vrijeme u kojem nema informacije o visini razine vode u menzuri. Zbog toga je stanje troputnog ventila tijekom snimanja postavljeno na unaprijed odabranu fiksnu vrijednost. Postupak time postaje potpuno analogan postupku snimanja karakteristike staze s pumpom. Ovdje se na kraju snimanja također sprema stanje troputnog ventila u varijablu TV .

3.1.5. Staza s pumpom, poremećajnim ventilima i troputnim ventilom (staza K)

Zadnja staza predstavlja cijeli sustav. Ona objedinjuje prethodne dvije staze iz čega slijedi da je postupak snimanja spoj prethodnih postupaka. To znači da se snaga pumpe i stanja poremećajnih ventila generiraju nasumično, dok se stanje troputnog ventila drži na jednoj unaprijed odabranoj konstantnoj vrijednosti.

Konačni podaci koji se spremaju na disk su VP , VH , VT , $VPVD$, $VPVL$, TV i H_p .


3.2. Analiza snimljenih podataka

Kako bi se snimljeni podaci mogli iskoristiti za izradu matematičkog modela i učenje neuronske mreže, potrebno ih je prethodno analizirati. Posebna pozornost posvećena je utjecaju elektronike na odziv sustava, odnosno na moguća kašnjenja i nejednolika očitavanja.

3.2.1. Vremenska razlika između koraka

Sustavu je potrebno otprilike 0,2 sekunde između dva očitavanja sa senzora visine. Za točniji podatak uzeto je jedno snimanje na stazi A, odnosno spremljeni vektor vremena VT iz kojeg su izračunati vremenski pomaci između koraka. Iz prikazanih pomaka [Slika 3.3] uočeno je da ta razlika nije uvijek jednaka. To se posebno odnosi na korake kod kojih dolazi i do promjene snage pumpe. Svako dodatno mijenjanje stanja, bilo da se radi o pumpi ili poremećajnim

ventilima, znači veći vremenski razmak između ta dva koraka. Zbog toga je zaključeno kako svi podaci moraju biti svedeni na isti korak, što se postiže diskretizacijom.



Slika 3.3 Vremenska razlika između koraka

3.2.2. Kašnjenje odziva pumpe i poremećajnih ventila

Snaga pumpe i stanja poremećajnih ventila jedina su stanja koja se aktivno mijenjaju tijekom snimanja. Zbog toga je potrebno provjeriti njihove odzive, odnosno utjecaj na brzinu promjene visine.

Za provjeru odziva pumpe uzimaju se podaci sa staze A i to vektori VP , VH i VT u malo izmijenjenom obliku (3.4).


$$\begin{aligned} VP &= [p_1 \ p_2 \ \dots \ p_n] \\ VH &= [H_p \ h_1 \ h_2 \ \dots \ h_n] \\ VT &= [0 \ t_1 \ t_2 \ \dots \ t_n] \end{aligned} \quad (3.4)$$

U vektor stanja visine VH dodana je početna visina H_p kako bi vektor bio iste dužine kao VT .

Iz ta se dva vektora zatim računa novi vektor brzina promjene visine prema izrazu (3.5).

$$VDH = \left[\frac{h_1 - H_p}{t_1 - 0} \ \frac{h_2 - h_1}{t_2 - t_1} \ \dots \ \frac{h_n - h_{n-1}}{t_n - t_{n-1}} \right] \quad (3.5)$$

Snaga koja se postavlja u trenutku $t = 0$ je snaga p_1 , stoga vektor VP vrijedi u svom originalnom obliku.




Slika 3.4 Brzina promjene visine u ovisnosti o snazi pumpe

Prikazani podaci [Slika 3.4] pokazuju kako postoji određeno kašnjenje kod označenih točaka. Razlog tome je što pumpa treba neko vrijeme da postigne novo zadanu vrijednost snage, prema slici jedan korak više. Taj problem riješen je na način da se vektoru snage na prvo mjesto doda vrijednost snage koja je bila aktivna prije početka snimanja. Ta je vrijednost kod svih snimanja uvijek ista i iznosi 40%. Da bi vektor ostao iste dužine, potrebno je ukloniti zadnju vrijednost snage, čime se dobiva konačni transformirani vektor snage (3.6).

$$\mathbf{VP} = [40 \ p_1 \ p_2 \ \dots \ p_{n-1}] \quad (3.6)$$

Analogan postupak slijedi za provjeru odziva poremećajnih ventila. Za to je potrebno učitati jedno od snimanja na stazi B te izračunati vektor brzina promjene visine kao u prethodnom slučaju.



Slika 3.5 Brzina promjene visine u ovisnosti o snazi pumpe i stanju poremećajnih ventila

Prikazani podaci [Slika 3.5] pokazuju kako kod poremećajnih ventila također postoji kašnjenje od jednog koraka. To znači da se problem može riješiti na isti način kao kod snage pumpe. Kašnjenja odziva pumpe ovdje nema, jer je unaprijed uređen vektor snage čime je ovdje provjerena točnost tog postupka. Za poremećajne ventile poznato je da su njihova stanja prije početka snimanja postavljena na nulu, odnosno da su zatvoreni. Iz toga slijede njihovi novi vektori stanja (3.7).

$$\begin{aligned} VPVD &= [0 \ sd_1 \ sd_2 \ \dots \ sd_{n-1}] \\ VPVL &= [0 \ sl_1 \ sl_2 \ \dots \ sl_{n-1}] \end{aligned} \quad (3.7)$$

Potreba za sređivanjem vektora snage i vektora stanja poremećajnih ventila dokazana je kasnije kod simulacije sustava matematičkim modelom i neuronskim mrežama.


3.3. Diskretizacija snimljenih mjerenja

Diskretizacija je postupak kojim se kontinuirani signal tijekom vremena svodi na diskretni oblik. Dobiveni podaci s makete diskretnog su oblika, ali vremenski korak između točaka nije jednak tijekom vremena. Zadatak diskretizacije u ovom je slučaju svesti dobivene točke u intervalu VT s makete na vremenski interval kod kojeg su svi koraci vremena jednaki.

To je postignuto interpolacijom točaka. Najprije se promatra staza A i odziv sustava na promjenu snage pumpe. Vektori koji sudjeluju u procesu su transformirani vektor snage VP , vektor visine VH i vektor vremena VT (3.8).

$$\begin{aligned} VP &= [40 \ p_1 \ p_2 \ \dots \ p_{n-1}] \\ VH &= [H_p \ h_1 \ h_2 \ \dots \ h_n] \\ VT &= [0 \ t_1 \ t_2 \ \dots \ t_n] \end{aligned} \quad (3.8)$$

Primjer interpolacije obavljen je za korak diskretizacije od 0,05 sekundi. Podaci nakon interpolacije prikazani su slikom [Slika 3.6].




Slika 3.6 Prikaz interpoliranih točaka uz originalno kašnjenje snage pumpe

Na slici se može jasno vidjeti kako snaga pumpe i promjena visine dobivaju nove međutočke. To je posljedica interpolacije koja vrijednosti za nepoznate korake u vremenu računa iz srednje vrijednosti susjednih točaka. Promatranjem odziva vidljivo je kako tražena snaga pumpe dostiže novu vrijednost prije nego odziv stvarnog sustava. To je riješeno na način da se vektor snage pomakne za još jedan korak unatrag, dodajući početnu snagu na početak vektora snage (3.9).

$$VP = [40 \ 40 \ p_1 \ p_2 \ \dots \ p_{n-2}] \quad (3.9)$$

Diskretizacija je ponovljena za novi vektor snage, a dobiveni podaci prikazani su slikom [Slika 3.7].



Slika 3.7 Prikaz interpoliranih točaka uz dodatno kašnjenje snage pumpe

Prikazani podaci potvrđuju bolju usklađenost promjene snage pumpe i odziva sustava. Iako izgleda da još uvijek postoji određeno odstupanje, testiranja matematičkog modela pokazala su da se ovim postupkom gotovo potpuno uklanjaju odstupanja povezana sa kašnjenjem odziva staze kod promjene snage pumpe.

Podaci o položaju poremećajnih ventila diskretiziraju se na isti način kao i snaga pumpe. Njihove interpolirane točke također su provjerene radi mogućeg kašnjenja, ali se kod njih ne javlja taj problem. Iz toga se može zaključiti kako je odziv staze uslijed promjene stanja poremećajnih ventila brži od odziva staze uslijed promjene snage pumpe.

4. IDENTIFIKACIJA SUSTAVA

Matematički model koristi razne jednadžbe za opisivanje ponašanja stvarnog modela. Te se jednadžbe nekad mogu unaprijed znati jer su neka ponašanja odavno poznata. Kod drugih složenijih ponašanja potrebno je odabrati odgovarajuću jednadžbu koja mora biti što jednostavnija da se model previše ne zakomplicira, a opet dovoljno točna da dobro opisuje sustav. To znači da je potrebno naći ravnotežu između jednostavnosti i točnosti funkcije matematičkog modela.

Sustav je najprije potrebno rastaviti na osnovne elemente. Osnovni elementi su oni koji utječu na promjenu visine tekućine u menzuri, a to su pumpa te troputni i poremećajni ventili. Budući da senzor na sustavu mjeri visinu tekućine, iz čega se može dobiti promjena visine, utjecaji elemenata promatraju se preko promjene visine. To znači da se umjesto protoka promatra brzina promjene visine, koja je s njim u direktnoj vezi preko jednadžbe (4.1).

$$D_h = \frac{Q}{A_m} \quad (4.1)$$

Površina presjeka menzure A_m je konstantna pa je time brzina promjene visine proporcionalna sa protokom. U daljnjim razmatranjima svi proračuni i jednadžbe svode se na računanje brzine promjene visine D_h koja se mjeri u mm/s .

Svaki od osnovnih dijelova sustava utječe na ukupnu brzinu promjene visine preko svojeg udjela, što se može napisati jednadžbom (4.2).

$$D_h = D_{hi}(H) + D_{hu}(P, P_{tv}) + D_{hid}(H) + D_{hil}(H) \quad (4.2)$$

Brzina promjene visine uslijed glavnog istjecanja D_{hi} te brzine promjene visine uslijed poremećajnih ventila D_{hid} i D_{hil} ovise jedino o trenutnoj visini tekućine i uvijek su negativnih vrijednosti jer se radi o istjecanjima. Brzina promjene visine uslijed utjecanja tekućine D_{hu} može se rastaviti na dvije komponente (4.3).

$$D_{hu} = D_{hp} P - D_{htv}(P_{tv}) \quad (4.3)$$

Brzina promjene visine uslijed utjecanja dobiva se iz brzine promjene visine koju daje pumpa D_{hp} umanjenom za brzinu promjene visine D_{htv} koju troputni ventil skreće prema spremniku.

Budući da je pumpa uvijek aktivna kad se uzima u obzir, brzina promjene visine uslijed utjecanja D_{hu} uvijek je pozitivna.

Prema navedenoj podjeli matematički model je rastavljen na slijedeće dijelove:

- a) glavno istjecanje D_{hi}
- b) istjecanje kroz poremećajne ventile D_{hid} i D_{hil}
- c) utjecanje preko pumpe D_{hp}
- d) redukcija utjecanja pumpe uslijed položaja troputnog ventila D_{htv} .

Dijelovi su poredani prema logičkom redoslijedu. Budući da je glavno istjecanje prisutno kod svih mjerenja, potrebno ga je prvog modelirati. S druge strane troputni ventil nema smisla bez poznavanja modela pumpe pa je on modeliran na kraju.

4.1. Identifikacija stalnog istjecanja

Istjecanje tekućine kroz otvor na dnu menzure jedini je dio sustava koji je stalno aktivan i na njega nije moguće utjecati. Prema Bernoullijevoj jednadžbi, odnosno prema reduciranom obliku koji govori o istjecanju tekućine kroz otvor na posudi, idealna brzina istjecanja tekućine računa se preko izraza (4.4).

$$v_i(t) = \overline{2gh(t)} \quad (4.4)$$

Realna brzina istjecanja (4.5) jednaka je reduciranoj idealnoj brzini za faktor α , koji ovisi o obliku otvora.

$$v(t) = \alpha v_i(t) = \alpha \overline{2gh(t)} \quad (4.5)$$

Protok tekućine kroz taj otvor (4.6) jednak je umnošku brzine tekućine v i površine otvora A_i .

$$Q(t) = A_i v(t) = A_i \alpha \overline{2gh(t)} \quad (4.6)$$

Kao što je već prije rečeno, sustav se promatra preko brzine promjene visine prema izrazu (4.1). Kombiniranjem sa izrazom (4.6) dobiva se konačni izraz za brzinu promjene visine uslijed glavnog istjecanja tekućine (4.7).


$$D_{Hi}(t) = \frac{A_i}{A_m} \alpha \overline{2gh(t)} \quad (4.7)$$

Visina h u jednadžbi (4.7) predstavlja udaljenost od gornje razine tekućine pa do donjeg ruba istjecanja. Stvarna visina H koju očitava senzor mjeri se od dna menzure pa do razine tekućine. Istjecanje ne počinje direktno kod otvora, nego se tamo nalazi cijev što znači da je donji rub istjecanja pomaknut za duljinu te cijevi h_i . Konstantne vrijednosti A_i , A_m , α , i g također se mogu zamijeniti koeficijentom k_i . Time je dobiven konačni izraz (4.8).

$$D_{hi}(t) = k_i \sqrt{H t + h_i} \quad (4.8)$$

To znači da je za matematičko modeliranje istjecanja potrebno saznati koeficijente k_i i h_i .


Snimanja koja su potrebna dobivena su na stazi I. Promatranjem snimanja [Slika 3.1] uočen je nelinearni pad, što je u skladu s očekivanjima.



Slika 4.1 Detaljniji prikaz točaka kod samog istjecanja

Na detaljnijem prikazu točaka [Slika 4.1] uočen je nejednoličan pad. Nagib pravca u točki predstavlja brzinu promjene visine. Zbog nejednolikog pada centralnoj točki dodane su susjedne te se kroz njih provlači pravac. Dobiveni nagib pravca zatim se sprema zajedno s

trenutnom visinom u toj točki. Postupak se ponavlja za sve točke i za sva snimanja. Nakon prikupljanja podataka traži se funkcija (4.8) kroz dobivene točke.



Slika 4.2 Podaci i funkcija glavnog istjecanja

Prikaz podataka i funkcije kroz njih [Slika 4.2] dokazuje dobar izbor funkcije. Time su dobiveni koeficijenti istjecanja (4.9) i konačna funkcija brzine promjene visine uslijed glavnog istjecanja (4.10).

$$\begin{aligned} k_i &= -0,176 \\ h_i &= 17,338 \end{aligned} \quad (4.9)$$

$$D_{hi} \ t = -0,176 \ H \ t + 17,338 \quad (4.10)$$

4.2. Identifikacija istjecanja kroz poremećajne ventile

Istjecanje kroz poremećajne ventile događa se kad su poremećajni ventili aktivni, što znači da se tim istjecanjima može upravljati, ali samo sa dva stanja. Za njih se pretpostavlja isto ponašanje kao i kod glavnog istjecanja kroz otvor na dnu menzure, što znači da za njih vrijede analogne jednadžbe (4.11).

$$\begin{aligned} D_{hid}(t) &= k_{id} \frac{H t + h_{id}}{H t + h_{il}} \\ D_{hil}(t) &= k_{il} \frac{H t + h_{il}}{H t + h_{il}} \end{aligned} \quad (4.11)$$

Za određivanje koeficijenata korištena su snimanja dobivena na proširenom tipu staze I. Kod proširenog oblika te staze pored glavnog istjecanja aktivno je i istjecanje kroz poremećajne ventile. Snimanja su obavljena za svaki poremećajni ventil zasebno jer se pretpostavlja da oba ventila nisu potpuno identična.

Postupak dobivanja nagiba pravca u pojedinoj točki analogan je postupku za glavno istjecanje, no ipak postoji i jedna mala razlika. Budući da je glavno istjecanje nemoguće isključiti, dobiveni nagibi pravca u sebi sadržavaju dvije promjene visine, jednu uslijed glavnog istjecanja i drugu uslijed istjecanja kroz (desni) poremećajni ventil (4.12).

$$D_h = D_{hi} + D_{hid} \quad (4.12)$$

Nagib pravca uslijed glavnog istjecanja D_{hi} moguće je izračunati jer je njegova funkcija (4.10) dobivena u prošlom postupku. Iz toga slijedi da se nagib pravca uslijed istjecanja kroz (desni) poremećajni ventil može dobiti jednostavnim oduzimanjem (4.13).

$$D_{hid} = D_h - D_{hi} \quad (4.13)$$


Dobiveni nagibi pravca samo za poremećajne ventile spremaju se zajedno s pripadajućom visinom, nakon čega su analognim postupkom dobiveni koeficijenti (4.14) i funkcije brzine promjene visine uslijed istjecanja kroz poremećajne ventile (4.15).

$$\begin{aligned} k_{id} &= -0,1214 \\ h_{id} &= 30,326 \end{aligned} \quad (4.14)$$


$$\begin{aligned} k_{il} &= -0,1222 \\ h_{il} &= 34,826 \end{aligned}$$

$$\begin{aligned} D_{hid} t &= -0,1214 \frac{H t + 30,326}{H t + 34,826} \\ D_{hil} t &= -0,1222 \frac{H t + 34,826}{H t + 34,826} \end{aligned} \quad (4.15)$$

Prikazani podaci i funkcije za desni [Slika 4.3] i lijevi [Slika 4.4] poremećajni ventil potvrđuju pretpostavljeno ponašanje.



Slika 4.3 Podaci i funkcija istjecanja desnog poremećajnog ventila




Slika 4.4 Podaci i funkcija istjecanja lijevog poremećajnog ventila

4.3. Identifikacija pumpe

Pumpa je najvažniji dio sustava, što znači da njezino modeliranje bitno utječe na ponašanje cijelog matematičkog modela. Za razliku od istjecanja, u ovom slučaju nije unaprijed poznata jednadžba koja bi opisivala ovisnost brzine promjene visine tekućine s obzirom na postotak snage pumpe.

Za dobivanje podataka iskorištena su snimanja dobivena na stazi A. Snimanje je prikazano preko brzine promjene visine između koraka [Slika 4.5].



Slika 4.5 Dobivanje podataka o brzini promjene visine s obzirom na snagu pumpe

Podaci o brzini promjene visine dobiveni su na način da se snimanje najprije podijeli na dijelove konstantne snage koji imaju više od tri točke. U prikazanom slučaju [Slika 4.5] postoji šest takvih dijelova. Svaka točka u sebi sadržava dvije brzine, traženu brzinu uslijed utjecanja pumpe te brzinu uslijed glavnog istjecanja (4.16).


$$D_h = D_{hp} + D_{hi} \quad (4.16)$$

Brzina uslijed utjecanja pumpe dobiva se oduzimanjem brzine uslijed istjecanja (4.17).

$$D_{hp} = D_h - D_{hi} \quad (4.17)$$

Nakon što je iz točaka oduzeta brzina promjene visine uslijed istjecanja, izračunava se srednja vrijednost dobivenih točaka prikazana linijom za svaki od šest dijelova [Slika 4.5]. Dobivena srednja vrijednost sprema se zajedno sa snagom pumpe kod tih točaka. Postupak je isti za sve dijelove te se ponavlja za sva dobivena snimanja na stazi A.


Dobiveni podaci prikazani su grafički [Slika 4.6] kako bi se mogao dobiti uvid u oblik funkcije ovisnosti.



Slika 4.6 Podaci o brzini promjene visine uslijed djelovanja pumpe

Primijećena su dva problema. Prvi problem je najočitiji i radi se naglom porastu brzine promjene visine kod 100% snage. Ta pojava vezana je uz PWM regulaciju snage pumpe, a radi se o tome što elektronika do 99% snage koristi PWM dok kod 100% pušta napon direktno na pumpu. Drugi problem javlja se kod malih postotaka snage pumpe, gdje pumpa nema dobro svojstvo ponovljivosti. Također se kod veće zatvorenosti troputnog ventila može pojaviti istjecanje kroz ulazni vod. Oba problema mogu se ukloniti odabirom povoljnog raspona postotka snage pumpe. Tako su sva snimanja ponovljena sa novim radnim područjem pumpe i to od 30% do 99% .

Nakon što su obavljena nova snimanja odabire se povoljna funkcija za estimaciju podataka.



Slika 4.7 Podaci i estimirana funkcija utjecanja uslijed djelovanja pumpe

Prema dobivenim podacima [Slika 4.7] zaključeno je kako bi za funkciju bio dovoljan polinom drugog stupnja (4.18).

$$D_{hp} \ t = p_2 P^2(t) + p_1 P(t) + p_0 \quad (4.18)$$

Odabrana funkcija jako dobro opisuje podatke, a njezini koeficijenti (4.19) vrijede za uvrštavanje snage P u postocima.

$$\begin{aligned} p_2 &= -0,0012 \\ p_1 &= 0,33 \\ p_0 &= 0,474 \end{aligned} \quad (4.19)$$

Koeficijenti su radi preglednosti spremljeni u vektor \mathbf{K}_p (4.20).

$$\mathbf{K}_p = \begin{bmatrix} p_2 & p_1 & p_0 \end{bmatrix} \quad (4.20)$$


4.4. Identifikacija troputnog ventila

Troputni ventil služi za skretanje tekućine koja dolazi iz pumpe u dva smjera, prema menzuri i prema spremniku. To znači da on ne utječe na pumpu prigušivanjem protoka, pa za pumpu vrijedi jednačba (4.18) dobivena otprije. Kod troputnog ventila potrebno je saznati na koji način njegov položaj djeluje na distribuciju tekućine. Umjesto da se utjecaj troputnog ventila svede na računanje udjela D_{htv} koji se vraća u spremnik (4.3), uveden je koeficijent redukcije R koji pokazuje koliki udio tekućine prolazi prema menzuri (4.21).

$$R = \frac{D_{hu}}{D_{hp}} = \frac{D_{hp} - D_{htv}}{D_{hp}} = f(P_{tv}) \quad (4.21)$$

Pri tome je D_{hu} brzina promjene visine koja ulazi u menzuru i koja je se računa iz podataka dobivenih snimanjem na stazi C uz poznato uklanjanje glavnog istjecanja. Brzina promjene visine uslijed djelovanja pumpe D_{hp} dobiva se iz poznate jednačbe (4.18). Postupak je analogan postupku kod traženja funkcije pumpe, dok se ovdje za svaku točku sprema i položaj troputnog ventila.

Iz dobivenih podataka prikazanih grafički [Slika 4.8] i temeljem testiranja došlo se do zaključka kako je za opisivanje redukcije utjecanja dovoljan polinom četvrtog stupnja (4.22).



Slika 4.8 Podaci i estimirana funkcija redukcije utjecanja uslijed zatvorenosti troputnog ventila

$$R = r_4 P_{tv}^4 + r_3 P_{tv}^3 + r_2 P_{tv}^2 + r_1 P_{tv} + r_0 \quad (4.22)$$

Izabrana funkcija dobro opisuje dobivene podatke, iako ovdje postoji veće odstupanje podataka. Dobiveni koeficijenti (4.23) vrijede uz uvrštavanje položaja troputnog ventila u postocima.

$$\begin{aligned} r_4 &= 1,85 \cdot 10^{-9} \\ r_3 &= -2,41 \cdot 10^{-5} \\ r_2 &= 5,306 \cdot 10^{-4} \\ r_1 &= -0,0037 \\ r_0 &= 0,9997 \end{aligned} \quad (4.23)$$

Koeficijenti funkcije redukcije utjecanja spremljeni su u vektor K_r (4.24).

$$K_r = \begin{bmatrix} r_4 & r_3 & r_2 & r_1 & r_0 \end{bmatrix} \quad (4.24)$$

5. IDENTIFIKACIJA SUSTAVA NEURONSKIM MREŽAMA

Neuronske mreže za razliku od matematičkog modela ne koriste egzaktnu jednadžbu za opisivanje nekog sustava. Njihova sposobnost identifikacije očituje se u strukturi i međusobnoj interakciji manjih i jednostavnijih dijelova nazvanih neuroni. Neuroni se slažu u slojeve koji na svom izlazu koriste unaprijed zadane aktivacijske funkcije. Time se dobiva struktura koja zatim uči na temelju snimljenih podataka. Učenje neuronske mreže predstavlja podešavanje propusnosti pojedinog neurona. Opširniji opis načina djelovanja opisan je u [2].

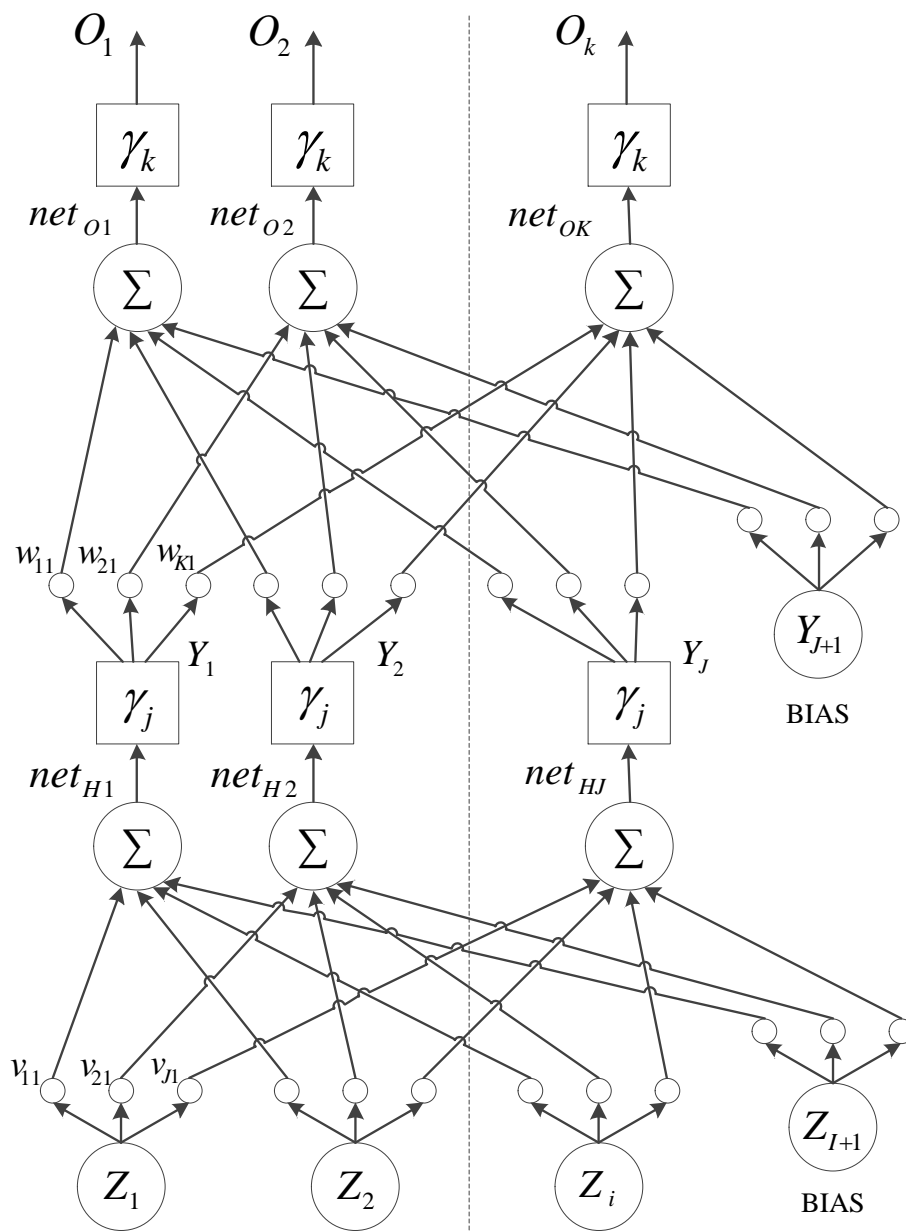
5.1. Statička unaprijedna neuronska mreža s povratnim prostiranjem pogreške (EBP)

Statička neuronska mreža jedna je od jednostavnijih. Pod statičkim se podrazumijeva statičko svojstvo neurona u toj mreži, što znači da sami neuroni ne pamte prethodnu vrijednost koja bi im bila potrebna za dinamiku. Unaprijedne neuronske mreže su mreže koje u svojem normalnom obliku nemaju povratnih veza, nego signal putuje samo unaprijed. Povratno prostiranje greške znači da se greška, koja se dobije na izlazu uspoređujući zadanu i dobivenu vrijednost, vraća od izlaza prema ulazu rasprostirući se kroz cijelu strukturu.


Navedena statička neuronska mreža najčešće se sastoji od tri sloja. Prvi sloj naziva se ulaznim i on služi za distribuciju ulaznih podataka u mrežu. Srednji sloj naziva se skrivenim zato jer vrijednosti u njemu nisu poznate, ali je njegova struktura najvažniji dio neuronske mreže. Zadnji sloj je izlazni sloj gdje se dobivene vrijednosti iz skrivenog sloja sumiraju čime se dobivaju traženi izlazni podaci.

Prema tome podaci putuju preko ulaznog sloja u skriveni te na kraju kroz izlazni gdje se dobivaju konačne vrijednosti. To je najlakše objasniti pomoću prikazane strukture [Slika 5.1]. Ulazi u mrežu Z_i mogu se promatrati kao ulazni neuroni. Njima je dodan još jedan neuron, zvan BIAS, koji ima vrijednost jednaku jedinici. Vrijednosti u ulaznim neuronima množe se sa pripadajućim težinama skrivenog sloja $v_{j,i+1}$ te zatim zbrajaju pri čemu se dobivaju sume net_{Hj} . Zatim dobivene sume prolaze kroz aktivacijsku funkciju γ_j koja je ista za sve neurone skrivenog sloja i sigmoidalnog je karaktera [Slika 5.2]. Nove dobivene vrijednosti označene su sa Y_j pri čemu je i ovdje dodan jedan BIAS neuron Y_{j+1} . Te vrijednosti množe se sa težinama izlaznog sloja $w_{k,j}$ čime se dobivaju sume izlaznog sloja net_{Ok} . Za dobivanje konačnih izlaza sume prolaze kroz aktivacijske funkcije izlaznog sloja. Budući da se u većini

slučajeva koristi linearna aktivacijska funkcija koja ulaz preslikava na izlaz, ova se operacija može i zanemariti.



Slika 5.1 Statička unaprijedna neuronska mreža



Slika 5.2 Aktivacijska funkcija skrivenog sloja neuronske mreže

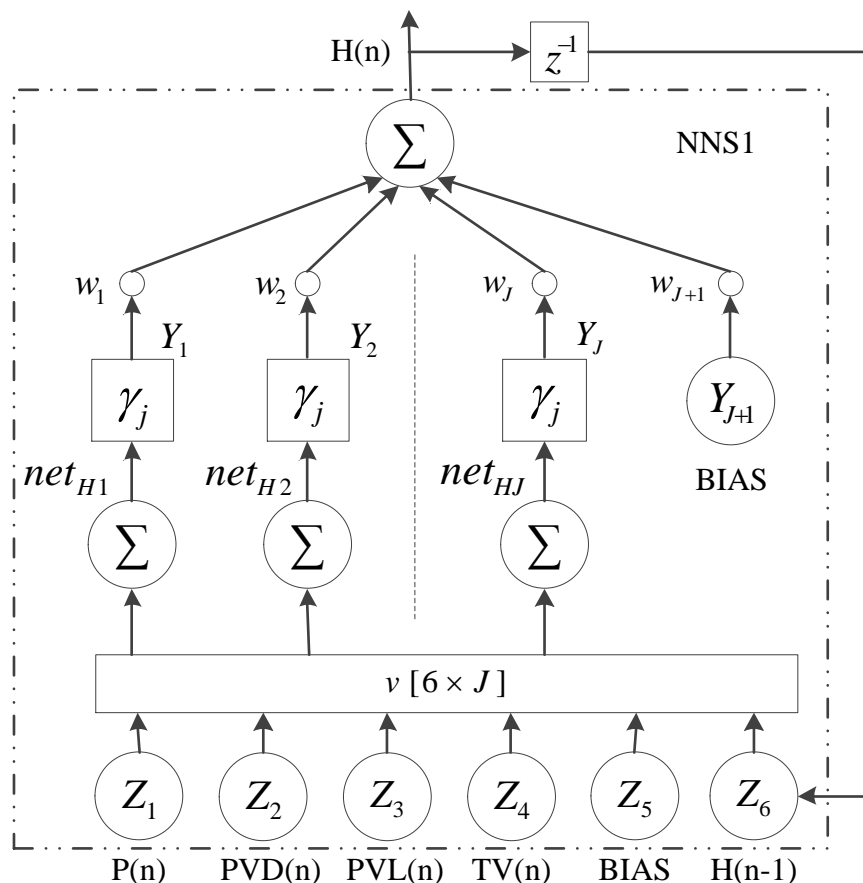
Učenje neuronske mreže svodi se na podešavanje težina skrivenog i izlaznog sloja. Da bi se mreža mogla naučiti, potrebno je za skup ulaznih podataka poznavati skup izlaznih podataka. Ti skupovi sastoje se od većeg broja uzoraka. Svaki uzorak predstavlja jednu kombinaciju ulaznih i izlaznih stanja preko kojih mreža uči. Detaljan postupak objašnjen je na konkretnoj neuronskoj mreži vezanoj za laboratorijski model, dok je općenito opisano u [2].

5.2. Statička neuronska mreža s povratnom vezom (NNS1)

Laboratorijski model promatra se preko visine tekućine u menzuri. Visina tekućine i njezina promjena ne ovisi direktno samo o stanjima drugih dijelova (pumpa, ventili), nego i o svojoj trenutnoj vrijednosti (istjecanje). To znači da ponašanje promatranog sustava također ovisi o njegovom trenutnom stanju što mora vrijediti i za neuronsku mrežu. Budući da statička unaprijedna neuronska mreža ne posjeduje povratne veze, potrebno ju je nadograditi. To se postiže vraćanjem trenutnog izlaza neuronske mreže na njezin ulaz. Time je broj ulaza povećan za jedan i to za trenutno stanje visine tekućine u menzuri.

Vraćanje signala sređeno je na drugačiji način nego u [2]. Umjesto da se matrica ulaznih podataka \mathbf{Z} proširuje, vraćanje je umetnuto u samu strukturu mreže.

Neuronska mreža promatrana je za konkretan slučaj, što znači da ima jedan izlaz koji predstavlja visinu tekućine u menzuri. Za broj ulaza odabran je maksimalan broj mogućih ulaza, a to su snaga pumpe te desni, lijevi i troputni ventil. Jedina promjenjiva vrijednost je broj skrivenih neurona J , a iz njega i dimenzije matrica težina \mathbf{v} i \mathbf{w} .



Slika 5.3 Statička neuronska mreža s povratnom vezom (NNS1)

Podaci o snimanju spremljeni su u odgovarajuće varijable. Ulazni podaci koji govore o stanju pojedinih dijelova sadržani su u matrici \mathbf{Z} (5.1). Svaki stupac predstavlja jedno stanje sustava, dok su u recima uzorci tih stanja koji se mijenjaju kroz vrijeme. Vremenski razmak između uzoraka uvijek je jednak, što je postignuto diskretizacijom. Prikazana matrica može također biti sa manje ulaza, ovisno o stazi koja se želi modelirati.

$$\mathbf{Z} = \begin{bmatrix} P_1 & PVD_1 & PVL_1 & TV_1 \\ P_2 & PVD_2 & PVL_2 & TV_2 \\ \vdots & \vdots & \vdots & \vdots \\ P_N & PVD_N & PVL_N & TV_N \end{bmatrix} \quad (5.1)$$

Jedino stanje sustava koje se mjeri i koje je potrebno simulirati je visina tekućine. Visina dobivena snimanjem uspoređuje se sa visinom dobivenom na izlazu neuronske mreže, te se na temelju greške mijenjaju težine u neuronskoj mreži. Poznata stanja visine spremljena su u vektoru \mathbf{D} (5.2).

$$\mathbf{D} = \begin{pmatrix} D_1 \\ D_2 \\ \vdots \\ D_N \end{pmatrix} \quad (5.2)$$

Visina ovisi o visini u prethodnom koraku, stoga je mreži također potrebno i početno stanje visine. Ono je spremljeno u posebnoj varijabli D_p (5.3).

$$D_p = D_0 = H_0 \quad (5.3)$$

Neuronske mreže učene su prema uzorku, što znači da se težine učenjem mijenjaju nakon prolaska kroz svaki uzorak. U svakom koraku n uzima se uzorak podataka \mathbf{Z}_n (5.4). Dobivenom vektoru dodaju se BIAS i visina u prethodnom koraku (5.5).

$$\mathbf{Z}(n) = [P_n \quad PVD_n \quad PVL_n \quad TV_n] \quad (5.4)$$

$$\mathbf{Z}(n) = [P_n \quad PVD_n \quad PVL_n \quad TV_n \quad 1 \quad H_{n-1}] \quad (5.5)$$

Za učenje neuronske mreže u MATLAB-u generiran je pomoćni vektor visine \mathbf{D}_d (5.6) u kojem se nalaze uzorci visina koji predstavljaju visine u prethodnom koraku.

$$\mathbf{D}_d = \begin{pmatrix} D_0 \\ D_1 \\ \vdots \\ D_{N-1} \end{pmatrix} \quad (5.6)$$

Time je dobiven vektor \mathbf{Z}_n koji se koristi kod učenja neuronske mreže (5.7).

$$\mathbf{Z}(n) = [P_n \quad PVD_n \quad PVL_n \quad TV_n \quad 1 \quad D_{d,n}] \quad (5.7)$$

Težine skrivenog sloja su težine koje raspoređuju ulazne podatke prema neuronima skrivenog sloja. Težine se spremaju u matricu \mathbf{v} (5.8) čije dimenzije ovise o broju ulaza uvećanom za dva ($4+2$) te o odabranom broju skrivenih neurona J .

$$\mathbf{v} = \begin{pmatrix} v_{1,1} & \cdots & v_{1,J} \\ \vdots & \ddots & \vdots \\ v_{6,1} & \cdots & v_{6,J} \end{pmatrix} \quad (5.8)$$

Za razliku od računanja sume skrivenih neurona net_H preko petlji za svaki član posebno [2], ovdje je uvedeno matrično množenje. Takvim odabirom uvelike se pojednostavljuje postupak

računanja, a u MATLAB-u se smanjuje broj potrebnih linija koda. Tako se vektor suma skrivenog sloja \mathbf{net}_H dobiva množenjem (5.9) vektora ulaza u pojedinom koraku \mathbf{Z}_n s matricom težina \mathbf{v} .

$$\mathbf{net}_H = \mathbf{Z}_n \times \mathbf{v} = \begin{bmatrix} net_{H1} & net_{H2} & \dots & net_{HJ} \end{bmatrix} \quad (5.9)$$

Zatim se na dobivenom vektoru suma primjenjuje prijenosna funkcija skrivenog sloja. U ovom slučaju radi se o skalarnom računanju za svaki element posebno. Time se dobiva vektor izlaza skrivenog sloja \mathbf{Y} (5.10).

$$\mathbf{Y} = \frac{2}{1 + e^{-\mathbf{net}_H}} - 1 = \begin{bmatrix} Y_1 & Y_2 & \dots & Y_J \end{bmatrix} \quad (5.10)$$

Vektoru je zatim dodan BIAS čime on postaje ulazni vektor izlaznog sloja (5.11).

$$\mathbf{Y} = \begin{bmatrix} Y_1 & Y_2 & \dots & Y_J & 1 \end{bmatrix} \quad (5.11)$$

Težine izlaznog sloja spremljene su u vektoru \mathbf{w} (5.12). Broj elemenata jednak je broju neurona skrivenog sloja J uvećan za jedan zbog dodanog BIAS-a.

$$\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_{J+1} \end{bmatrix} \quad (5.12)$$

Konačni izlaz neuronske mreže H_n dobiva se vektorskim umnoškom (5.13) vektora ulaza izlaznog sloja \mathbf{Y} sa vektorom težina izlaznog sloja \mathbf{w} .

$$H_n = \mathbf{Y} \times \mathbf{w} = Y_1 \cdot w_1 + Y_2 \cdot w_2 + \dots + 1 \cdot w_{J+1} \quad (5.13)$$

Zbog nepostojanja prijenosne funkcije izlaznog sloja račun je pojednostavljen, a izlaz mreže predstavlja visinu tekućine dobivenu u n -tom koraku H_n . Time završava unaprijedna faza računanja izlaza.

Sljedeća faza je povratna u kojoj je potrebno mijenjati težine slojeva prema algoritmu povratnog prostiranja greške. Za podatak o odstupanju dobivene visine H_n od stvarne visine D_n odabrana je suma kvadratne pogreške [3] prema izrazu (5.14).

$$E = \frac{1}{2} \sum (D_n - H_n)^2 \quad (5.14)$$

Za promjenu težina izlaznog sloja potrebno je izračunati gradijent pogreške ∇E_w za te težine. On se računa parcijalnim deriviranjem prema izrazu (5.15).

$$\nabla E_w = \frac{\partial E}{\partial \mathbf{w}} \quad (5.15)$$

Zbog jednostavnijeg pisanja u MATLAB-u gradijent je označen sa \mathbf{G}_w . Parcijalnu derivaciju potrebno je rastaviti na manje uzastopne parcijalne derivacije (5.16).

$$\mathbf{G}_w = \nabla E_w = \frac{\partial E}{\partial \mathbf{w}} = \frac{\partial E}{\partial H_n} \cdot \frac{\partial H_n}{\partial \mathbf{w}} \quad (5.16)$$

Prvi član (5.17) u MATLAB-u se označava sa $dEdH$, a dobiva se deriviranjem izraza (5.14).

$$dEdH = \frac{\partial E}{\partial H_n} = -(D_n - H_n) \quad (5.17)$$

Drugi član (5.18) dobiva se deriviranjem izraza (5.13).

$$\frac{\partial H_n}{\partial \mathbf{w}} = \mathbf{Y} \quad (5.18)$$

Konačni vektor gradijenata težina izlaznog sloja dobiva se množenjem ta dva člana (5.19). Budući da njegove dimenzije moraju biti jednake dimenzijama vektora težina izlaznog sloja, potrebno je transponirati drugi član.

$$\mathbf{G}_w = H_n - D_n \cdot \mathbf{Y}^T \rightarrow J + 1 \times 1 \quad (5.19)$$

Prema algoritmu povratnog prostiranja greške [3] promjena težina odvija se prema izrazu (5.20).

$$\mathbf{w}_n = \mathbf{w} - \eta \cdot \mathbf{G}_w + \alpha \cdot \mathbf{w} - \mathbf{w}_s - \beta(\mathbf{w}_s - \mathbf{w}_{ss}) \quad (5.20)$$

Novi vektor težina \mathbf{w}_n dobiva se oduzimanjem vektora gradijenata \mathbf{G}_w od trenutnog vektora težina \mathbf{w} . Jačina te promjene kontrolira se koeficijentom brzine učenja η , a učenje se ubrzava dodavanjem momentuma. U [2] opisano je dodavanje momentuma prvog reda (α) dok je ovdje također dodan momentum drugog reda [4]. Koeficijent momentuma prvog reda α određuje se korisnički, dok koeficijent momentuma drugog reda β ovisi o prvom prema izrazu (5.21).

$$\beta = \frac{\alpha - 1}{3} \quad (5.21)$$

S \mathbf{w}_s i \mathbf{w}_{ss} označene su težine u prethodnim koracima prije promjene, budući da se koeficijenti momentuma množe sa razlikom između težina u prethodnim koracima. Te vrijednosti moraju se pamtit i osvježavati kroz cijelo učenje u MATLAB-u.

Analogan postupak vrijedi za promjenu težina skrivenog sloja. Gradijent pogreške tih težina ∇E_v računa se također preko parcijalne derivacije, odnosno rastavom na umnožak uzastopnih parcijalnih derivacija (5.22).

$$\mathbf{G}_v = \nabla E_v = \frac{\partial E}{\partial \mathbf{v}} = \frac{\partial E}{\partial H_n} \cdot \frac{\partial H_n}{\partial \mathbf{Y}} \cdot \frac{\partial \mathbf{Y}}{\partial \mathbf{net}_H} \cdot \frac{\partial \mathbf{net}_H}{\partial \mathbf{v}} \quad (5.22)$$

Prvi je član poznat, dok se drugi član dobiva parcijalnim deriviranjem izraza (5.13). Budući da BIAS skrivenog sloja nema povratne veze, njegova težina w_{j+1} se ne uzima u obzir čime se dobiva konačan izraz (5.23).

$$\frac{\partial H_n}{\partial \mathbf{Y}} = \mathbf{w}(1:J) = \begin{matrix} w_1 \\ w_2 \\ \vdots \\ w_J \end{matrix} \quad (5.23)$$

Treći član dobiva se derivacijom prijenosne funkcije skrivenog sloja (5.10). Prema [3] vrijedi konačni izraz (5.24) s tim da se izračun radi skalarno, odnosno za svaki element vektora \mathbf{Y} zasebno. Također je potrebno izostaviti otprije dodani BIAS.

$$\frac{\partial \mathbf{Y}}{\partial \mathbf{net}_H} = \frac{1}{2} (1 - \mathbf{Y}(1:J)^2) \rightarrow 1 \times J \quad (5.24)$$

Zadnji član dobiva se derivacijom izraza (5.9) i jednak je ulaznom vektoru stanja prema izrazu (5.25).

$$\frac{\partial \mathbf{net}_H}{\partial \mathbf{v}} = \mathbf{Z}(n) \rightarrow 1 \times 6 \quad (5.25)$$

Budući da je korišteno matrično množenje, dobivene parcijalne derivacije potrebno je međusobno pomnožiti u smjeru izlaza prema ulazu. Najprije se kombiniraju prva dva člana prema izrazu (5.26).

$$\frac{\partial E}{\partial \mathbf{Y}} = \frac{\partial E}{\partial H_n} \cdot \frac{\partial H_n}{\partial \mathbf{Y}} = \mathbf{H}_n - \mathbf{D}_n \cdot \mathbf{w}(1:J) \rightarrow J \times 1 \quad (5.26)$$

Sljedeći korak je množenje sa trećim članom. Da bi to bilo moguće potrebno je transponirati umnožak prva dva člana (5.26) i skalarno ih pomnožiti sa trećim članom prema izrazu (5.27).

$$\frac{\partial E}{\partial \mathbf{net}_H} = \frac{\partial E}{\partial \mathbf{Y}} \cdot \frac{\partial \mathbf{Y}}{\partial \mathbf{net}_H} = \mathbf{H}_n - \mathbf{D}_n \cdot \mathbf{w}(1:J)^T \cdot \frac{1}{2}(1 - \mathbf{Y}^2) \rightarrow 1 \times J \quad (5.27)$$

Matrica gradijenata težina skrivenog sloja \mathbf{G}_v mora biti istih dimenzija kao matrica težina skrivenog sloja v . To se dobiva transponiranjem zadnjeg člana $\mathbf{Z}(n)$ i matričnim množenjem (5.28) sa prethodno dobivenim vektorom (5.27).

$$\mathbf{G}_v = \frac{\partial E}{\partial \mathbf{net}_H} \cdot \frac{\partial \mathbf{net}_H}{\partial v} = \mathbf{Z}_n^T \times \frac{\partial E}{\partial \mathbf{net}_H} \rightarrow 6 \times J \quad (5.28)$$

Kombiniranjem prethodnih izraza (5.26), (5.27) i (5.28) dobiva se potpuni izraz (5.29) za računanje matrice gradijenata težina skrivenog sloja.

$$\mathbf{G}_v = \mathbf{Z}_n^T \times \mathbf{H}_n - \mathbf{D}_n \cdot \mathbf{w}(1:J)^T \cdot \frac{1}{2}(1 - \mathbf{Y}^2) \rightarrow 6 \times J \quad (5.29)$$

Promjena težina skrivenog sloja odvija se po istom algoritmu kao promjena težina izlaznog sloja prema izrazu (5.30). I u ovom se slučaju moraju spremati matrice težina u prethodnim koracima \mathbf{v}_s i \mathbf{v}_{ss} zbog korištenja momentuma prvog i drugog reda.

$$\mathbf{v}_n = \mathbf{v} - \eta \cdot \mathbf{G}_v + \alpha \cdot \mathbf{v} - \mathbf{v}_s - \beta(\mathbf{v}_s - \mathbf{v}_{ss}) \quad (5.30)$$

Postupak računanja greške i podešavanja težina ponavlja se za svaki uzorak. Nakon prolaska kroz sve uzorke potrebno je izračunati točnost algoritma, odnosno brojem prikazati koliko se neuronska mreža približila stvarnom sustavu. Kod svih neuronskih mreža računa se normalizirani korijen srednje kvadratne pogreške (engl. NRMS) prema izrazu (5.31).

$$\text{NRMS} = \frac{RMS}{\sigma_{d_n}} = \frac{\sqrt{\frac{\sum_{n=1}^N (D_n - H_n)^2}{N}}}{\sqrt{\frac{1}{N} \sum_{n=1}^N (D_n - D)^2}} \stackrel{\text{MATLAB}}{=} \frac{\text{norm}(\mathbf{D} - \mathbf{H})}{\sqrt{\frac{1}{N} \sum_{n=1}^N (D_n - D)^2}} = \frac{\text{norm}(\mathbf{D} - \mathbf{H})}{\text{std}(\mathbf{D}, 1)} \quad (5.31)$$

Vektor visine \mathbf{H} u kojem su spremljene dobivene visine preko neuronske mreže uspoređuju se sa stvarnim visinama spremljenim u vektoru \mathbf{D} (5.2). Broj N predstavlja broj uzoraka, a izrazu (5.31) je također dodan prikaz postupka u MATLAB-u. Ovaj način računanja točnosti korišten je također i kod matematičkog modela budući da ga je potrebno usporediti sa neuronskim mrežama.

Opisana neuronska mreža razlikuje se od matematičkog modela prema načinu opisivanja sustava. Matematički model koristi jednadžbe za opisivanje brzine promjene visine D_h , odnosno promjene visine dH_{MM} opisane izrazom (5.32).

$$H_n = H_{n-1} + dH_{MM}(Z_n) \quad (5.32)$$

To znači da se matematičkim modelom sustav opisuje preko integracijskog djelovanja. S druge strane neuronska mreža nema odvojeno integracijsko djelovanje nego ona na izlazu direktno daje traženu visinu u sljedećem koraku (5.33).

$$H_n = H_{NN}(Z_n) \quad (5.33)$$

Zbog te razlike i problema koji su se pojavili kod testiranja neuronske mreže kreirana je modificirana neuronska mreža kojoj je integracijsko djelovanje dodano izvan same strukture.

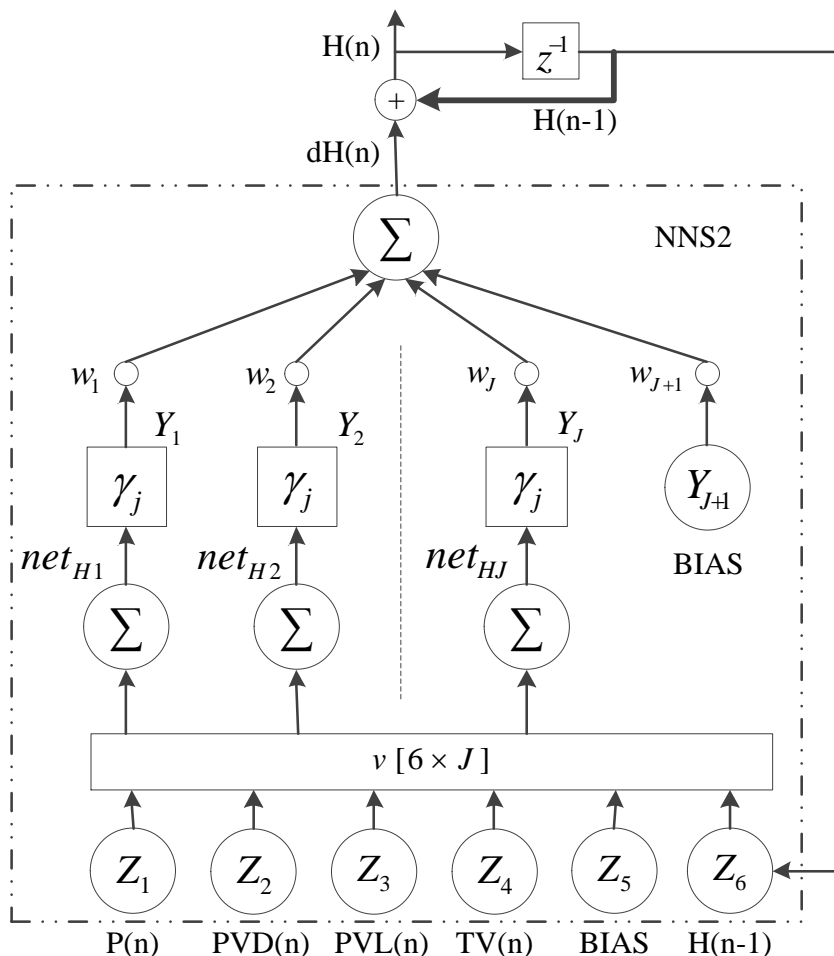
5.3. Statička neuronska mreža s povratnom vezom i integracijskom petljom (NNS2)

Neuronska mreža sa integracijskom petljom ima dodanu povratnu vezu na svom izlazu kako bi se približila matematičkom modelu. To znači da neuronska mreža opisuje sustav preko promjene visine dH_{NN} , koja se zatim zbraja sa visinom u prethodnom koraku (5.34).

$$H_n = H_{n-1} + dH_{NN}(Z(n)) \quad (5.34)$$

Izraz (5.34) potpuno je analogan izrazu matematičkog modela (5.32), što znači da se ova neuronska mreža može s njim direktno usporediti.

Za dobivanje integracijske petlje na izlazu neuronske mreže povučena je dodatna povratna veza koja se može vidjeti na prikazanoj strukturi [Slika 5.4]. Povratna veza omogućuje neuronskoj mreži da na svom izlazu daje traženu promjenu visine, a ne traženu visinu. To olakšava učenje mreže, što će biti dokazano kod testiranja neuronskih mreža.



Slika 5.4 Statička neuronska mreža s povratnom vezom i integracijskom petljom (NNS2)

Zbog te povratne veze potrebna je manja prilagodba jednadžbi. Izraz (5.13) mijenja se u izraz (5.35) koji vrijedi kod učenja, te u izraz (5.36) koji vrijedi kod testiranja neuronske mreže.

$$H_n = dH_n + D_{a\ n} = Y \times w + D_{a\ n} \quad (5.35)$$

$$H_n = dH_n + H_{n-1} = Y \times w + H_{n-1} \quad (5.36)$$

Ostale jednadžbe kod algoritma učenja ostaju jednake budući da parcijalna derivacija izraza (5.35) u sebi ne sadrži dodani član.

U svim daljnjim razmatranjima pod NNS1 se podrazumijeva neuronska mreža s povratnom vezom koja na svom izlazu daje traženu visinu. Sa NNS2 označena je neuronska mreža s povratnom vezom i integracijskom petljom koja na svom izlazu daje promjenu visine. Ta se promjena visine uslijed integracijske petlje zbraja sa prethodnom visinom čime se dobiva tražena visina.

6. TESTIRANJE I USPOREDBA REZULTATA DOBIVENIH MATEMATIČKIM MODELOM I NEURONSKIM MREŽAMA

Matematički model i neuronske mreže potrebno je usporediti sa stvarnim podacima dobivenim na maketi. Njihovi rezultati također su međusobno uspoređeni. Ulazni podaci koji su potrebni za testiranje su stanja aktivnih elemenata i početna visina. Ulazni podaci diskretizirani su na odabrani korak ΔT . Broj aktivnih elemenata, a time i ulaza, ovisi o stazi koja se promatra. Rezultati dobiveni simulacijom uspoređuju se sa stvarnim podacima, a za informaciju o grešci korišteni su parametar NRMS i maksimalna vrijednost odstupanja visine dH_{max} .

Testiranje matematičkog modela svodi se na računanje visine H_n preko promjene visine dH_{MM} u svakom koraku i pribrajanja prethodnoj visini tekućine H_{n-1} prema izrazu (6.1).

$$H_n = H_{n-1} + dH_{MM} \quad (6.1)$$

Promjena visine dH_{MM} ovisi o umnošku brzine promjene visine tekućine D_h i odabranom koraku diskretizacije ΔT prema izrazu (6.2).

$$dH_{MM} = D_h \cdot \Delta T \quad (6.2)$$

Brzina promjene visine tekućine D_h prema izrazu (4.2) ovisi o aktivnim elementima, što znači da se ona dobiva preko jednadžbi dobivenih identifikacijom modela.

Neuronske mreže uče na temelju diskretiziranih podataka. Pritom korak diskretizacije ΔT mora biti jednak onom korištenom kod testiranja matematičkog modela. Obje neuronske mreže kao rezultat daju visinu tekućine tijekom vremena.

6.1. Staza s pumpom (staza A)

6.1.1. Matematički model

Najprije je testirana staza s pumpom. Kod ove staze ukupna brzina promjene visine tekućine ovisi o utjecanju tekućine uslijed pumpe i istjecanju kroz otvor na dnu menzure (4.16). Troputni ventil nije aktivan u ovoj stazi pa je brzina promjene visine uslijed utjecanja D_{hu} jednaka brzini promjene uslijed snage pumpe D_{hp} . Prema tome slijedi konačan izraz (6.3) za računanje visine na stazi s pumpom.

$$H_n = H_{n-1} + D_{hp} + D_{hi} \cdot \Delta T \quad (6.3)$$


Testiranje je provedeno na svim mjerenjima koja su korištena kod identifikacije. Kod svakog mjerenja izračunat je NRMS i maksimalna razlika visine dH_{max} . Nakon prolaska kroz sva mjerenja izračunate su prosječne vrijednosti. Na početku su testiranja provedena za različit iznos koraka diskretizacije ΔT radi provjere utjecaja na točnost simulacije. Dobivene vrijednosti prikazane su u tablici [Tablica 6.1].

Tablica 6.1 Utjecaj koraka diskretizacije na grešku matematičkog modela


Korak diskretizacije ΔT [s]	0,2	0,1	0,05	0,02	0,01
Prosječni NRMS	0,0291	0,0264	0,0254	0,0250	0,0249
Prosječna max razlika visine ΔH_{max} [mm]	2,7468	2,5954	2,5682	2,5628	2,5638

Iz dobivenih vrijednosti može se zaključiti kako upotreba manjeg koraka diskretizacije ne utječe puno na točnost matematičkog modela. Stoga je za daljnja razmatranja korišten korak diskretizacije od desetinke sekunde, dok će ovaj utjecaj kod neuronskih mreža biti pokazan kasnije.

Nakon odabira koraka diskretizacije prikazuju se rezultati matematičkog modela preko NRMS-a [Slika 6.1] i preko maksimalne razlike visine ΔH_{max} [Slika 6.2]. Iz prikazanih slika vidljivo je kako su NRMS i maksimalna razlika visine za pojedino mjerenje sličnog. To znači da nema potrebe za računanjem maksimalne razlike visine nego je tu grešku dovoljno prikazati pomoću NRMS-a. Usporedba također pokazuje kako vrijednost NRMS-a približno opisuje maksimalnu razliku visine mjerenu u decimetrima.




Slika 6.1 NRMS matematičkog modela na stazi A




Slika 6.2 Maksimalna razlika visine matematičkog modela i staze A

Za dokaz točnosti i generalizacije odabran je prikaz najveće i najmanje greške između matematičkog modela i staze A. Najveća greška nalazi se pod brojem 21 i prikazana je na slici [Slika 6.3], dok je najmanja greška pod brojem 81 i prikazana slikom [Slika 6.4]. Promatranjem slika zaključeno je kako matematički model dobro generalizira stazu A što dokazuje dobru identifikaciju pumpe i istjecanja kroz otvor na dnu menzure.

U prilogu [III] dani su dodatni prikazi grešaka između matematičkog modela i staze A.



Slika 6.3 Prikaz najveće greške između matematičkog modela i staze A



Slika 6.4 Prikaz najmanje greške između matematičkog modela i staze A

6.1.2. Neuronske mreže

Nakon matematičkog modela slijedi učenje neuronskih mreža. Neuronske mreže na stazi A imaju ukupno tri ulaza, snagu pumpe i BIAS u promatranom trenutku te visinu u prethodnom koraku (6.4).

$$Z(n) = P_n - 1 - H_{n-1} \quad (6.4)$$

Učenje neuronskih mreža najčešće se obavlja na jednom uzorku. U ovom slučaju odabran je uzorak koji daje najmanju grešku matematičkog modela i staze A, a to je uzorak pod brojem 81. Podaci uzorka o visini i snazi pumpe moraju se normirati i to u području od -1 do 1. To se postiže dijeljenjem visine H s 310 te dijeljenjem postotka snage pumpe P sa 100. Obje mreže, NNS1 i NNS2, učene su na istim parametrima (6.5) i s dva neurona u skrivenom sloju.

$$\begin{aligned} \eta &= 0,01 \\ \alpha &= 0,1 \\ \beta &= f \quad \alpha = -0,3 \end{aligned} \quad (6.5)$$

Početne težine generirane su nasumično i to u rasponu od -0,1 do 0,1.

Učenje se odvija tako dugo dok se ne postigne odabrani NRMS na uzorku učenja. Zatim se računa NRMS naučene neuronske mreže za svaki uzorak staze A kao što je to bio slučaj kod

matematičkog modela. Iz dobivenih NRMS-a izračunava se prosječna vrijednost NRMS-a (*NRMS*). Nakon toga učenje se nastavlja do sljedećeg iznosa NRMS-a ili dok učenje ne ode u zasićenje. Učenje neuronskih mreža provedeno je za dva različita koraka diskretizacije ΔT . Najbolji rezultati učenja za neuronsku mrežu NNS1 nalaze se u tablici [Tablica 6.2].

Tablica 6.2 Rezultati učenja neuronske mreže NNS1 na uzorku broj 81 staze A

Minimalni NRMS kod učenja		0,07	0,05	0,04	0,035	0,0305
$\Delta T = 0,1$	Broj obavljenih koraka	70000	87000	104000	133000	173000
	Prosječni NRMS (<i>NRMS</i>)	0,0666	0,0539	0,0481	0,0453	0,0424
Minimalni NRMS kod učenja		0,12	0,11	0,1	0,09	0,08
$\Delta T = 0,05$	Broj obavljenih koraka	73000	77000	85000	101000	276000
	Prosječni NRMS (<i>NRMS</i>)	0,1323	0,1256	0,1191	0,1127	0,1049

Rezultati učenja neuronske mreže NNS1 kod koraka diskretizacije 0,1 sekunde pokazuju kako mreža uči do iznosa NRMS-a od 0,0305 nakon čega ide u zasićenje. Za manji korak diskretizacije zasićenje se događa na većem iznosu NRMS-a. Iznos prosječnog NRMS-a pokazuje kako mreža NNS1 postiže manju grešku za veći korak diskretizacije. Prije analize potrebno je pogledati rezultate učenja neuronske mreže NNS2 u tablici [Tablica 6.3].

Tablica 6.3 Rezultati učenja neuronske mreže NNS2 na uzorku broj 81 staze A

Minimalni NRMS kod učenja		0,05	0,04	0,03	0,025	0,02
$\Delta T = 0,1$	Broj obavljenih koraka	12000	14000	16000	18000	23000
	Prosječni NRMS (<i>NRMS</i>)	0,0442	0,0360	0,0327	0,0325	0,0338
$\Delta T = 0,05$	Broj obavljenih koraka	8000	10000	14000	19000	50000
	Prosječni NRMS (<i>NRMS</i>)	0,0407	0,0358	0,0338	0,0338	0,0343
$\Delta T = 0,01$	Broj obavljenih koraka	18000	21000	34000	/	/
	Prosječni NRMS (<i>NRMS</i>)	0,0512	0,0444	0,0391	/	/


Kod neuronske mreže NNS2 prosječni NRMS je manji i ne povećava se toliko kod manjeg koraka diskretizacije ΔT . Zasićenje se događa samo za najmanji korak diskretizacije, dok kod ostalih koraka nema smisla učiti mrežu do zasićenja jer je najmanja prosječna greška postignuta za NRMS kod učenja jednak 0,025. Potreban broj koraka učenja također je puno

manji s obzirom na neuronsku mrežu NNS1. Usprkos dobrim rezultatima učenja, naučene neuronske se mreže razlikuju od matematičkog modela. Razlika je u tome što se za identifikaciju koriste svi uzorci staze A, dok je za učenje mreža upotrijebljen samo jedan uzorak. Zbog toga je izabran novi način učenja neuronskih mreža.

Učenje neuronskih mreža odvija se po skupu svih uzoraka staze A. Jednim prolaskom kroz taj skup obavi se 88 koraka učenja (promjena svih parametara učenja u neuronskoj mreži), što je jednako ukupnom broju dostupnih uzoraka staze A. Redoslijed uzoraka u skupu nije uvijek jednak nego je nasumično generiran, a kako bi svaki prolazak kroz taj skup bio različit. Nakon svakog prolaska kroz skup dobivena se neuronska mreža testira na sve uzorke staze A te se računa prosječni NRMS. Ako prosječni NRMS postigne dotad najmanju vrijednost, težine se spremaju u zasebnu datoteku, a učenje nastavlja sve do zasićenja.

Učenje po skupu uzoraka osigurava izbjegavanje lokalnih minimuma koji se mogu javiti kod učenja na samo jedan uzorak. To se vidi kod rezultata učenja neuronske mreže NNS2 [Tablica 6.3] gdje se daljnjim učenjem povećao prosječni NRMS. Učenje po skupu uzoraka obavljeno je za obje neuronske mreže uz različit broj neurona skrivenog sloja N_h i za dva različita koraka diskretizacije ΔT . Mreže uče tako dugo dok nema vidljivog smanjivanja prosječnog NRMS-a, odnosno dok učenje ode u zasićenje.

Učenje po skupu svih uzoraka karakterizira nejednolik pad NRMS-a [Slika 6.5] za razliku od učenja na jedan uzorak. To je posljedica različitog redoslijeda uzoraka u skupu. Najveći utjecaj ima uzorak koji je zadnji u skupu, budući da je prema njemu mreža učila zadnja tik pred testiranjem. Ako u uzorku postoji veće odstupanje, mreža se odmiče od globalnog minimuma pa se zbog toga u nekim točkama javlja porast prosječnog NRMS-a.




Slika 6.5 Karakteristični pad NRMS-a kod učenja po skupu uzoraka

Rezultati učenja po skupu prikazani su u tablici [Tablica 6.4].


Tablica 6.4 Rezultati učenja neuronskih mreža po skupu svih uzoraka staze A

Mreža	NNS1				NNS2			
ΔT	0,1		0,02		0,1		0,02	
N_h	NRMS	Koraci	NRMS	Koraci	NRMS	Koraci	NRMS	Koraci
1	0,0626	57000	0,3484	160000	0,0277	43000	0,0300	43000
2	0,0592	60000	0,3364	140000	0,0273	13000	0,0279	9000
3	0,0571	73000	0,1140	160000	0,0276	8000	0,0294	11000
5	0,0372	200000	0,1593	170000	0,0277	22000	0,0279	3500
8	0,0317	500000	/	/	/	/	/	/

Dobiveni rezultati pokazuju da učenje po skupu smanjuje prosječni NRMS i to u manje obavljenih koraka. Ako se promatra utjecaj koraka diskretizacije vidljivo je kako veći korak daje bolje rezultate kod obje mreže. To je posebno izraženo kod neuronske mreže NNS1, dok je utjecaj kod mreže NNS2 gotovo zanemariv. Radi bolje usporedbe prikazani su rezultati simulacije neuronskih mreža za oba koraka diskretizacije. Za međusobnu usporedbu odabran je uzorak broj 22 staze A kod kojeg obje neuronske mreže imaju najveću grešku.



Slika 6.6 Prikaz najveće greške između neuronskih mreža i staze A za $\Delta T = 0,1$ s



Slika 6.7 Prikaz najveće greške između neuronskih mreža i staze A za $\Delta T=0,02$ s

Prikazana greška [Slika 6.6] pokazuje kako neuronske mreže dobro generaliziraju stazu A za korak diskretizacije od 0,1 sekunde. Za korak diskretizacije od 0,02 sekunde [Slika 6.7] povećano je odstupanje kod neuronske mreže NNS1, dok je mreža NNS2 zadržala svoju točnost. U prilogu [III] dani su dodatni prikazi grešaka između neuronskih mreža i staze A.

Veća greška kod neuronske mreže NNS1 posljedica je integracijskog svojstva sustava. Kod neuronske mreže NNS1 integracija se odvija u samoj mreži, dok je kod mreže NNS2 realizirana integracijskom petljom. Kao što je napomenuto prije, mreža NNS1 na izlazu daje visinu, dok mreža NNS2 daje promjenu visine. To znači da mreža NNS1 promjenu visine pribraja prethodnoj visini u svojoj strukturi. Te dvije vrijednosti također su međusobno zavisne jer zbog istjecanja promjena visine ovisi o trenutnoj visini. To se može objasniti pomoću izraza (6.6) za mrežu NNS1 i izraza (6.7) za mrežu NNS2.

$$H_{n+1} = f_{NNS1} H_n, dH = f_{NNS1}(H_n, f'_{NNS1} Z_n) \quad (\text{NNS1}) \quad (6.6)$$

$$H_{n+1} = H_n + dH = H_n + f_{NNS2} Z_n \quad (\text{NNS2}) \quad (6.7)$$

Iz prvog izraza vidljivo je kako se kod učenja mreže NNS1 usklađuju dvije funkcije zavisnosti, f_{NNS1} i f'_{NNS2} . Drugi izraz potvrđuje kako se dodavanjem integracijske petlje na izlaz mreže NNS2 učenje pojednostavljuje jer se učenje svodi na nalaženje samo jedne

funkcije zavisnosti f_{NNS2} . Smanjenje greške kod mreže NNS1 za veći korak diskretizacije riješeno je povećavanjem broja neurona u skrivenom sloju.

Kod manjeg koraka diskretizacije javlja se novi problem. Manji korak znači manju vrijednost promjene visine dH . U izrazu (6.6) za mrežu NNS1 visina H_n ostaje u istom normiranom rasponu vrijednosti dok je promjena visine dH smanjena pet puta. To znači veću razliku između funkcija a time i njihovo otežano usklađivanje. Kod mreže NNS2 tog usklađivanja nema jer mreža uči samo promjenu visine, pa smanjenje te promjene znači samo smanjivanje težina.

Ukratko se može reći kako mreža NNS2 daje bolje rezultate na stazi A budući da se njezino učenje svodi na estimaciju promjene visine, a ne estimaciju konačne visine.

Uslijed toga sva daljnja razmatranja baziraju se na koraku diskretizacije od desetinke sekunde, budući da za njega sva tri modela pokazuju najbolje rezultate.

6.1.3. Međusobna usporedba modela

Nakon što su poznati uvjeti za međusobnu usporedbu, prelazi se na analizu rezultata. Najprije su najbolji rezultati modela i neuronskih mreža prikazani u zajedničkoj tablici [Tablica 6.5].

Tablica 6.5 Najbolji rezultati modela i mreža staze A s korakom diskretizacije 0,1 s

Model	Matematički model	Neuronska mreža NNS1	Neuronska mreža NNS2
<i>NRMS</i>	0,0264	0,0317	0,0273
Broj parametara	5 (2+3)	33 (4·8+1)	9 (4·2+1)
N_h	/	8	2
Koraci učenja	/	500000	13000

Promatranjem konačne točnosti pojedinog modela, može se zaključiti kako matematički model daje najbolji rezultat. Neuronske mreže imaju malo veću grešku, ali je tu razliku najbolje predočiti preko visine. Kod matematičkog modela je spomenuto kako NRMS otprilike predstavlja maksimalnu razliku visine modela i staze u decimetrima. Prema tome ispada kako neuronske mreže imaju prosječnu grešku veću samo za pola milimetra, što je zanemarivo.

Za usporedbu složenosti svih modela potrebno je izračunati broj njihovih parametara. Matematički model na stazi A sastoji se od pumpe (4.18) i glavnog istjecanja (4.10), što broji

ukupno pet parametara. Kod neuronskih mreža broj parametara jednak je ukupnom broju težinskih koeficijenata u matricama \mathbf{v} i \mathbf{w} . Njihove dimenzije ovise o broju skrivenih neurona i broju ulaza. Broj parametara za stazu A dobiva se iz izraza (6.8), pri čemu je s N_z broj ulaza.


$$N_{parA} = N_{zA} \cdot N_h + N_h + 1 \cdot 1 = 3N_h + N_h + 1 = 4N_h + 1 \quad (6.8)$$

Usporedba broja parametara pokazuje kako matematički model koristi najmanje parametara za razliku od neuronske mreže NNS1 kojoj su potrebna čak 33 parametra da se približi matematičkom modelu. Neuronska mreža NNS2 koristi 9 parametara, ali to je u slučaju najmanje greške. Ako se iz tablice [Tablica 6.4] uzme mreža sa jednim neuronom u skrivenom sloju, ispada da je njezin broj parametara jednak matematičkom modelu, dok je razlika greške gotovo zanemariva.


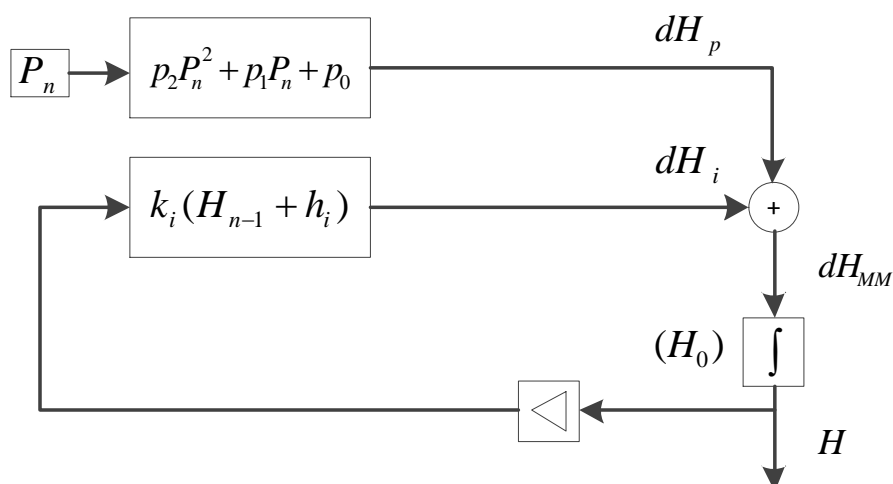
Također ne treba zanemariti broj koraka učenja neuronskih mreža, gdje mreža NNS2 uči puno brže od mreže NNS1 koja ima i manju točnost.

Konačni zaključak je kako matematički model i neuronska mreža NNS2 najbolje opisuju stazu A. Iako matematički model daje malo bolje rezultate, potrebno je naglasiti kako je za njegovu realizaciju potrebno više posla. Za stazu A bilo je potrebno identificirati istjecanje i pumpu, prikupljanjem podataka i pronalaženjem dobrih funkcija za estimaciju tih podataka. S druge strane kod neuronske mreže potrebno je samo diskretizirati podatke na koje mreža uči. Time je cijeli posao estimacije obuhvaćen učenjem neuronske mreže.

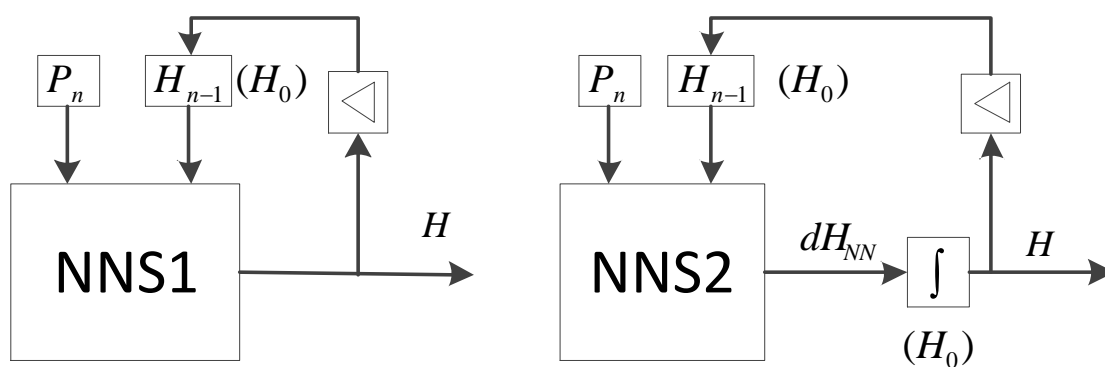
Na slikama [Slika 6.8] i [Slika 6.9] prikazana je greška neuronskih mreža na stazi A, kako bi ih se moglo međusobno usporediti s greškom matematičkog modela na slici [Slika 6.1].



Slika 6.8 NRMS neuronske mreže NNS1 na stazi A za $\Delta T=0,1s$

Slika 6.9 NRMS neuronske mreže NNS2 na stazi A za $\Delta T=0,1s$ 

Slika 6.10 Shematski prikaz matematičkog modela staze A



Slika 6.11 Shematski prikaz neuronskih mreža staze A

6.2. Staza s pumpom i poremećajnim ventilima (staza B)

Staza B je staza na kojoj pored pumpe postoji i utjecaj poremećajnih ventila. Poremećajni ventili stvaraju samo dodatno istjecanje iz menzure pa je za očekivati slične rezultate kao kod staze A.

Za matematički model vrijedi isti slučaj kao kod staze A. Razlika je u tome što se u izraz (6.3) dodaju promjene visine uslijed otvorenosti poremećajnih ventila. Budući da su te promjene aktivne samo dok su ventili otvoreni, potrebno je uvesti varijable stanja poremećajnih ventila. Kod neuronskih mreža ta stanja označena su sa PVD i PVL . Te varijable imaju samo dvije moguće vrijednosti, nulu za zatvoreno i jedinicu za otvoreno stanje ventila. Iz toga slijedi konačan izraz (6.9) matematičkog modela za računanje visine na stazi s pumpom i poremećajnim ventilima (staza B).

$$H_n = H_{n-1} + D_{hp} + D_{hi} + PVD_n \cdot D_{hid} + PVL_n \cdot (D_{hil}) \cdot \Delta T \quad (6.9)$$

Testiranje matematičkog modela na stazi B obavljeno je na isti način kao i kod prethodne staze. Pritom je korišten otprije dogovoren korak diskretizacije od desetinke sekunde.

Neuronske mreže dobivaju dva nova ulaza, čime je broj ulaza povećan na pet (6.10).


$$\mathbf{Z}(n) = [P_n \ PVD_n \ PVL_n \ 1 \ H_{n-1}] \quad (6.10)$$

Broj neurona skrivenog sloja jednak je broju neurona korištenih kod neuronskih mreža staze A. To znači osam neurona za mrežu NNS1, dok je za mrežu NNS2 korišten jedan neuron u skrivenom sloju. Mreže su učene prema skupu svih uzoraka staze B, kojih je bilo 44.

Rezultati matematičkog modela i neuronskih mreža prikazani su u tablici [Tablica 6.6], a grafički prikaz greške na slici [Slika 6.12].

Tablica 6.6 Najbolji rezultati modela i mreža staze B s korakom diskretizacije 0,1 s

Model	Matematički model	Neuronska mreža NNS1	Neuronska mreža NNS2
$NRMS$	0,0187	0,0451	0,0358
Broj parametara	9 (2+3+2+2)	49 (6·8+1)	7 (6·1+1)
N_h	/	8	1
Koraci učenja	/	640000	270000




Slika 6.12 NRMS modela i neuronskih mreža staze B za $\Delta T=0,1s$

Broj parametara kod matematičkog modela povećao se na osam zbog dodavanja dvaju poremećajnih ventila. Broj parametara neuronskih mreža (6.11) dobiva se na analogan način kao kod staze A (6.8), osim što u ovom slučaju postoji pet ulaznih neurona ($N_{zB} = 5$).

$$N_{parB} = N_{zB} \cdot N_h + N_h + 1 \cdot 1 = 5N_h + N_h + 1 = 6N_h + 1 \quad (6.11)$$

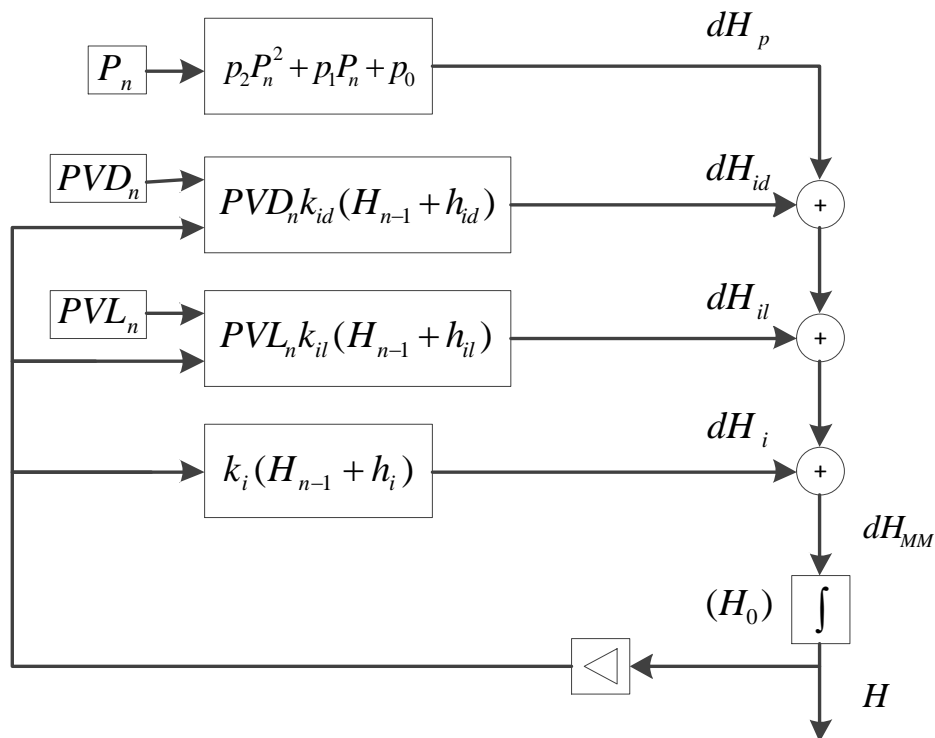
Prikazani rezultati pokazuju kako matematički model daje najbolje rezultate, dok neuronske mreže imaju grešku veću približno za 2 do 3 mm. To ne vrijedi za neka mjerenja gdje se greška penje do čak 10 mm. Iako je ta vrijednost unutar 5% ukupnog raspona promatranog sustava (od 100 do 300 mm), potrebno je grešku prikazati slikom. Odabrani uzorak nalazi se pod brojem jedan i prikazan je na slici [Slika 6.13]. Ostali karakteristični uzorci dani su u prilogu [VI].




Slika 6.13 Prikaz najveće greške između neuronskih mreža i staze B

Iz prikazanih odziva može se primijetiti kako razlika visine kod obje neuronske mreže raste tijekom vremena. To je posljedica integracijskog karaktera sustava, gdje se sve greške zbrajaju tijekom vremena što na kraju znači veće odstupanje. Usprkos većoj razlici visina, generalizacija je dobra, budući da odziv neuronskih mreža prati konturu staze B.

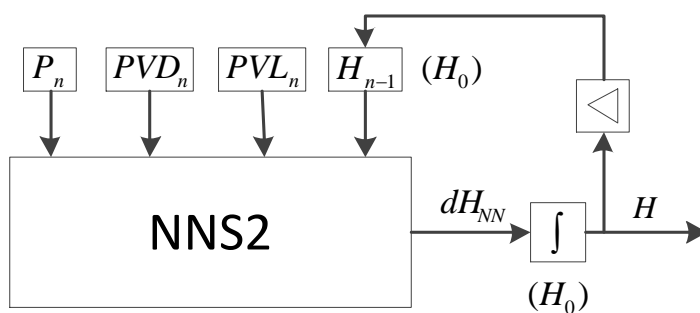
Matematički model i kod ove staze pokazuje bolje rezultate. Razlog je u tome što je identifikacija rađena za svaki element posebno, dok se učenje neuronskih mreža odvija na podacima koji uključuju sve elemente na toj stazi. Iako postoje uzorci na kojima se javljaju veća odstupanja, može se zaključiti kako i u ovom slučaju neuronske mreže dobro estimiraju zadani sustav.



Slika 6.14 Shematski prikaz matematičkog modela staze B



Slika 6.15 Shematski prikaz neuronske mreže NNS1 staze B



Slika 6.16 Shematski prikaz neuronske mreže NNS2 staze B

6.3. Staza s pumpom i troputnim ventilom (staza C)

Nakon staze s poremećajnim ventilima potrebno je promotriti stazu s pumpom i troputnim ventilom. Kod ove staze poremećajni ventili ne uzimaju se u obzir.

Matematički model staze C (6.12) dobiva se dodavanjem koeficijenta redukcije R u izraz (6.3). Koeficijent redukcije ovisi o položaju troputnog ventila prema izrazu (4.22).

$$H_n = H_{n-1} + R \cdot D_{hp} + D_{hi} \cdot \Delta T \quad (6.12)$$

Za neuronske mreže na stazi C potrebna su ukupno četiri ulaza (6.13).

$$Z(n) = [P_n \quad TV_n \quad 1 \quad H_{n-1}] \quad (6.13)$$

Podaci su diskretizirani na korak od desetinke sekunde kao i kod prethodnih staza. Postupak učenja mreža i testiranje modela i mreža potpuno je analogan postupku na prethodnoj stazi. Obje mreže učene su s različitim brojem neurona skrivenog sloja, ali su testiranja pokazala kako broj neurona za stazu C odgovara broju neurona za stazu B. Neuronske mreže uče prema skupu svih uzoraka staze C tako dugo dok NRMS ne ode u zasićenje. U tablici [Tablica 6.7] prikazani su najbolji rezultati matematičkog modela i neuronskih mreža za stazu C.

Tablica 6.7 Najbolji rezultati modela i mreža staze C s korakom diskretizacije 0,1 s


Model	Matematički model	Neuronska mreža NNS1	Neuronska mreža NNS2
NRMS	0,0309	0,0750	0,0775
Broj parametara	10 (2+3+5)	41 (5·8+1)	6 (5·1+1)
N_h	/	8	1
Koraci učenja	/	650000	270000

Rezultati pokazuju kako matematički model staze C daje dvostruko manju grešku od neuronskih mreža. Pritom je po prvi puta neuronska mreža NNS1 dala bolje rezultate od mreže NNS2, iako joj je potreban veći broj parametara. Broj parametara neuronskih mreža za stazu C računa se iz izraza (6.14).


$$N_{parC} = N_{zC} \cdot N_h + N_h + 1 \cdot 1 = 4N_h + N_h + 1 = 5N_h + 1 \quad (6.14)$$

Mreži NNS1 također je potrebno više koraka učenja, a zanimljivo je da je broj koraka učenja za obje mreže jednak broju koraka učenja kao kod staze B.


Za detaljniju analizu potrebno je NRMS prikazati grafički za svaki uzorak staze C. Na slikama [Slika 6.17], [Slika 6.18] i [Slika 6.19] prikazan je NRMS uz dodatnu informaciju o položaju troputnog ventila za svaki uzorak. Relativna vrijednost zatvorenosti troputnog ventila prikazana je točkama.



Slika 6.17 NRMS matematičkog modela staze C za $\Delta T=0,1s$




Slika 6.18 NRMS neuronske mreže NNS1 na stazi C za $\Delta T=0,1s$



Slika 6.19 NRMS neuronske mreže NNS2 na stazi C za $\Delta T=0,1s$

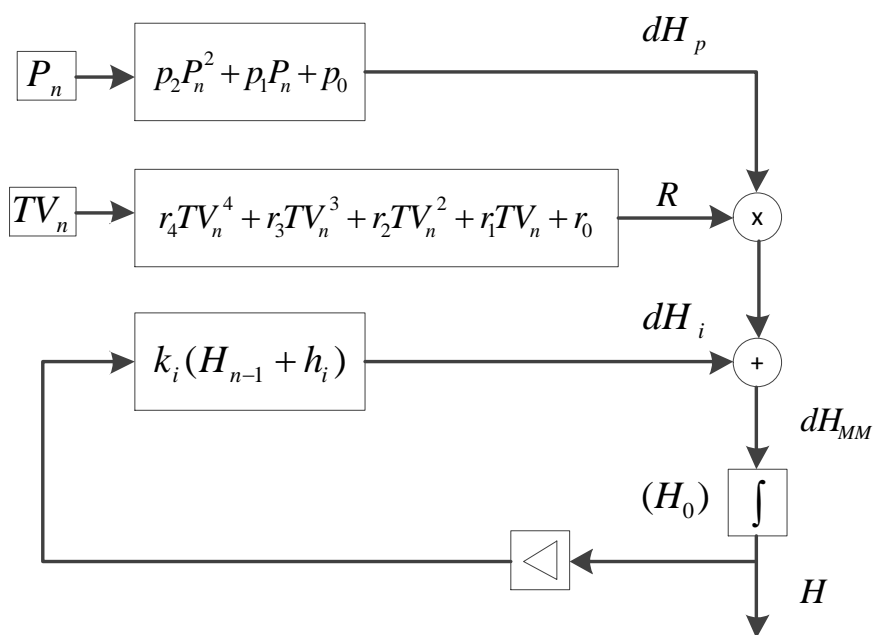
Iz prikazanog NRMS-a vidljivo je kako se najveća greška između neuronskih mreža i staze C javlja kod veće zatvorenosti ventila. Pritom je iznos greške pojedinog uzorka približno jednak za obje mreže. Iznos najveće greške govori kako u najgorem slučaju odstupanje između neuronskih mreža i staze C može iznositi i do 25 mm stupca tekućine. Ostala odstupanja su manja i penju se do 10 mm. Odstupanje matematičkog modela puno je manje i ne povećava se kod veće zatvorenosti troputnog ventila.

Iz ovog primjera očito je kako neuronske mreže imaju problema kod graničnih vrijednosti ulaza, iako mreže uče na sve uzorke staze C. Radi uvida u odstupanje neuronskih mreža odabran je uzorak 14 staze C prikazan slikom [Slika 6.20].




Slika 6.20 Prikaz najveće greške između neuronskih mreža i staze C


Iz prikazane greške može se zaključiti kako se ne radi o lokalnom povećanju greške nego se greška povećava kroz sve korake vremena. To znači da je odstupanje neuronskih mreža posljedica netočne estimacije redukcije utjecanja za veći iznos zatvorenosti troputnog ventila. Prikazi ostalih grešaka dani su u prilogu [IX].



Slika 6.21 Shematski prikaz matematičkog modela staze C



Slika 6.22 Shematski prikaz neuronske mreže NNS1 staze C



Slika 6.23 Shematski prikaz neuronske mreže NNS2 staze C

6.4. Staza s pumpom, poremećajnim ventilima i troputnim ventilom (staza K)

Staza koja uključuje sve elemente na maketi nazvana je stazom K. Kod nje se promatra utjecaj svih aktivnih elemenata, pa se stazom K može smatrati kombinacija staze B i staze C. Prema tome se matematički model staze K (6.15) dobiva kombiniranjem izraza za stazu B (6.9) i izraza za stazu C (6.12).

$$H_n = H_{n-1} + R \cdot D_{hp} + D_{hi} + PVD_n \cdot D_{hid} + PVL_n \cdot (D_{hil}) \cdot \Delta T \quad (6.15)$$

Broj ulaza kod neuronskih mreža jednak je maksimalnom broju ulaza (6.16).

$$\mathbf{Z}(n) = \begin{bmatrix} P_n & PVD_n & PVL_n & TV_n & 1 & H_{n-1} \end{bmatrix} \quad (6.16)$$

Mreže uče prema skupu svih uzoraka staze K sve dok NRMS ne ode u zasićenje. Broj neurona skrivenog sloja jednak je broju kao i kod prethodnih staza.

Najbolji rezultati za matematički model i neuronske mreže prikazani su u tablici [Tablica 6.8].

Tablica 6.8 Najbolji rezultati modela i mreža staze K s korakom diskretizacije 0,1 s

Model	Matematički model	Neuronska mreža NNS1	Neuronska mreža NNS2
<i>NRMS</i>	0,0855	0,1225	0,1076
Broj parametara	14 (2+3+2+2+5)	49 (6·8+1)	7 (6·1+1)
N_h	/	8	1
Koraci učenja	/	370000	230000


Matematički model staze K ima veće prosječno odstupanje nego je to bio slučaj kod drugih staza. Usprkos tome neuronske mreže još uvijek imaju veće odstupanje nego matematički model.

Zanimljivo je kako neuronska mreža NNS2 ima ponovo manju grešku od mreže NNS1. Ako se promotre rezultati svih staza može se reći kako dodatna istjecanja uslijed poremećajnih ventila utječu na veće odstupanje mreže NNS1. Time je dokazano kako mreža NNS1 ima problema kod dvostruke zavisnosti jednog ulaza, u ovom primjeru visine tekućine.

Broj parametara neuronskih mreža staze K računa se prema izrazu (6.17).

$$N_{parK} = N_{zK} \cdot N_h + N_h + 1 \cdot 1 = 5N_h + N_h + 1 = 6N_h + 1 \quad (6.17)$$

Gledajući broj parametara modela i mreža vidljivo je kako je neuronskoj mreži NNS2 potrebno manje parametara od matematičkog modela. Iz toga se može zaključiti kako neuronske mreže imaju prednost kod složenijeg sustava kao što je staza K, iako imaju malo veću prosječnu grešku. Da bi se provjerilo odstupanje potrebno ga je prikazati grafički. Greške matematičkog modela i neuronskih mreža staze K prikazane su na slici [Slika 6.24].




Slika 6.24 NRMS matematičkog modela i neuronskih mreža staze K za $\Delta T=0,1s$


Iz prikazanih grešaka vidljivo je približavanje točnosti neuronskih mreža matematičkom modelu. Najveće greške neuronskih mreža javljaju se za uzorke 11, 12 i 13 kod kojih je troputni ventil u najviše zatvorenom položaju. To je bilo za očekivati budući da se isti problem pojavio kod testiranja neuronskih mreža staze C. Ostali uzorci, osim prvog, pokazuju kako neuronske mreže rade približno istu pogrešku kao i matematički model. Približna vrijednost pogreške mjerene u visini stupca tekućine iznosi 8 mm.

Za prikaz odziva matematičkog modela i neuronskih mreža odabrani su uzorci 1 [Slika 6.25] i 20 [Slika 6.26]. Na prvom uzorku vidi se kako matematički model i neuronske mreže u jednom dijelu povećavaju svoje odstupanje, nakon čega ni ne prate stazu K. To znači da se vjerojatno radi o slučajnoj grešci u samom uzorku staze K. Na drugom uzorku vidi se karakterističan odziv matematičkog modela i neuronskih mreža. Iako se tijekom vremena pojavljuje odstupanje, može se primijetiti kako je ipak postignuta dobra generalizacija. U prilogu [XII] dani su dodatni prikazi grešaka na stazi K.

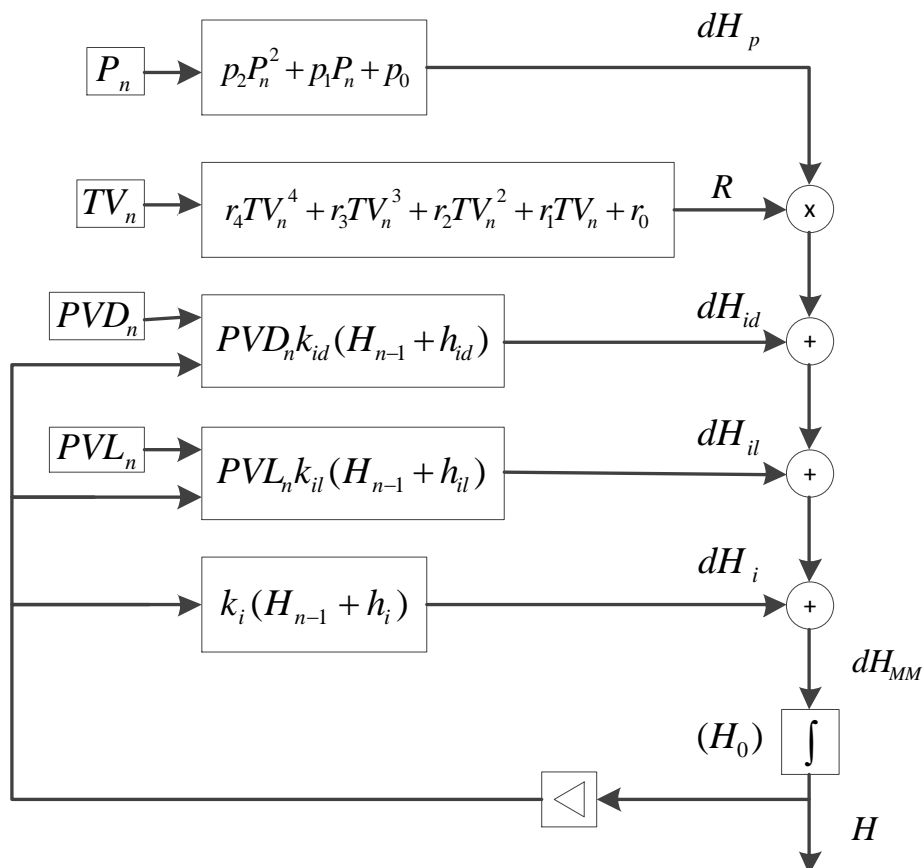
Zaključeno je kako se kod složenijeg sustava sa više varijabli stanja neuronske mreže postupno približavaju točnosti matematičkog modela. Njihova međusobna razlika također ovisi puno o identifikaciji svake staze. Kao što je već otprije rečeno, matematički model zasniva se na identifikaciji koja je rađena za svaki element posebno, dok neuronske mreže uče odjednom na uzorcima koji sadržavaju sve varijable stanja.




Slika 6.25 Prikaz greške modela i mreža staze K na uzorku broj 1



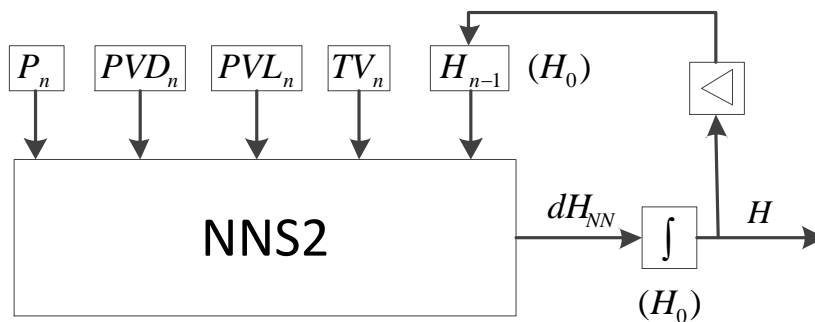
Slika 6.26 Prikaz greške modela i mreža staze K na uzorku broj 20



Slika 6.27 Shematski prikaz matematičkog modela staze K



Slika 6.28 Shematski prikaz neuronske mreže NNS1 staze K



Slika 6.29 Shematski prikaz neuronske mreže NNS2 staze K

7. ZAKLJUČAK

Općenito testiranje matematičkim modelom pokazalo je kako očitani podaci dobiveni sa stvarnog sustava sadržavaju kašnjenja koja su posljedica dinamike sustava. Tim su kašnjenjima prilagođeni ulazni podaci korišteni za matematički model i statičke neuronske mreže. Očitani podaci sa senzora također su sadržavali određeni šum, što je dodatno otežalo proces identifikacije.

Modeliranje staze s pumpom (staza A) pokazalo je da se pravilnim izborom funkcija matematičkog modela postiže veća točnost spram neuronskih mreža. S druge strane neuronske mreže za svoje učenje traže samo točan skup ulaznih podataka, dok se njihova sposobnost učenja i točnost očituje u pravilnom izboru strukture i načina učenja.

Modeliranje staze s pumpom i poremećajnim ventilima (staza B) pokazalo je da matematički model još uvijek ima veliku prednost naspram neuronskih mreža. Pritom je neuronska mreža s integracijskom petljom povećala svoju točnost naspram verzije bez integracijske petlje.

Na stazi s pumpom i troputnim ventilom (staza C) uočen je problem kod neuronskih mreža. Rezultati su pokazali da se njihova greška znatno povećava kod gornje granične vrijednosti položaja troputnog ventila. U budućem radu bi za uklanjanje tog efekta bilo potrebno neuronsku mrežu učiti na veću graničnu vrijednost, a koristiti, odnosno testirati za manju. Neuronske mreže postigle su otprilike istu točnost, ali za 4 mm veće odstupanje od matematičkog modela.

Model cijelog sustava (staza K) pokazuje kako kombinacija svih elemenata utječe na veću grešku matematičkog modela i neuronskih mreža. Pritom je prosječna greška neuronskih mreža naspram matematičkog modela smanjena na 2 mm. Time je pokazano kako se većim brojem elemenata i njihovom interakcijom povećava greška matematičkog modela.

Gledajući sve staze neuronska mreža s integracijskom petljom postiže bolje rezultate od mreže bez petlje. Razlog tome je utjecaj izlazne varijable (visine) na njezinu promjenu, što je posebice vidljivo kod manjeg koraka diskretizacije.

Bitno je naglasiti kako je ovaj rad podloga za daljnja istraživanja na promatranom laboratorijskom modelu. Matematički model potrebno je nadograditi samo za troputni ventil, dok kod drugih elemenata nije moguće postići veću točnost. Bolji rezultati neuronskih mreža mogu se postići izborom druge strukture i načina učenja.

LITERATURA


- [1] Petrić, D.: Diplomski rad, Fakultet strojarstva i brodogradnje, Zagreb, 2005.
- [2] Turnar, R.: Završni rad, Fakultet strojarstva i brodogradnje, Zagreb, 2010.
- [3] Novaković, B., Majetić, D., Široki, M.: Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [4] Pearlmutter, B.: Gradient Descent: Second-Order Momentum and Saturating Error, 1994.

PRILOZI

1. Specifikacije senzora položaja
2. Prikaz grešaka matematičkog modela i neuronskih mreža
3. CD-R disk

Product Specifications

CSPR
IP65/67




INFORMATION

The CSPR IP65/67 is offered as a self-interrogation model only. The CSPR IP65/67 contains all of the electronics needed to power the sensor and provide PWM and analog voltage outputs in a remote-electronics package, which allows the sensor head to remain small. You can choose from four different cable lengths (cable length is measured from the sensor head to the remote-electronics module).

NOTE: The standard magnet for the CSPR IP65/67 sensor is part number 401842.

PWM Output Style

The PWM output is high active, which means, its high level time represents the distance from the flange to the magnet center line (see sketch below).



The voltage high depends on the customer circuit. The sensor output stage is an open collector NPN-Transistor, and can handle voltages up to 30V.

Use the following method to calculate the time for the PWM high phase:

$$PWM_{HIGH} = 0.392 \frac{\mu s}{mm} \cdot x + 18.5 \mu s$$

where x is the distance of the magnet centerline to the beginning of the active stroke.

The period T , with which the output is repeated, is defined to:

$$1.5ms < T < 3.0ms$$

All dimensions in mm.

All specifications are subject to change. Please contact MTS for specifications critical to your needs. Refer to the website for additional information, (www.mtssensors.com).

Voltage Output Style

Voltage output from the sensor is ratiometric with the input voltage. Table 1 below shows the value, in percent of input voltage power, of the A (beginning of measurement range) and B (end of measurement range) points on the sensor as shown in the product illustration. Table 2 below gives these values in voltage for a 5.00V supply.

Table 1

Sensor stroke	Output at A	Output B
72.3 mm	35.1%Vs	90.0%Vs
109.5 mm	26.7%Vs	90.0%Vs
128.3 mm	23.8%Vs	90.0%Vs
148.0 mm	21.4%Vs	90.0%Vs
162.3 mm	20.0%Vs	90.0%Vs
186.3 mm	17.9%Vs	90.0%Vs
192.3 mm	17.4%Vs	90.0%Vs
194.3 mm	17.3%Vs	90.0%Vs
217.3 mm	15.8%Vs	90.0%Vs
250.1mm	14.0%Vs	90.0%Vs

Table 2

Sensor stroke	Output at A with 5.00V supply	Output B with 5.00V supply
72.3 mm	1.76V	4.50V
109.5 mm	1.34V	4.50V
128.3 mm	1.19V	4.50V
148.0 mm	1.07V	4.50V
162.3 mm	1.00V	4.50V
186.3 mm	0.90V	4.50V
192.3 mm	0.87V	4.50V
194.3 mm	0.87V	4.50V
217.3 mm	0.79V	4.50V
250.1mm	0.70V	4.50V

Part Numbers

The following table provides part numbers for CSPR sensor styles. Note that the CSPR is available with four choices of cable length between the sensor head and the remote-electronics module.

CSPR IP65/67				
Sensor Length mm	Interconnect Cable Length (Pigtail from remote 1 meter)			
1000 mm	750 mm	500 mm	300 mm	
72.3	280277-1	280278-1	280279-1	280280-1
109.5	280277-3	280278-3	280279-3	280280-3
128.3	280277-4	280278-4	280279-4	280280-4
148.0	280277-5	280278-5	280279-5	280280-5
162.3	280277-6	280278-6	280279-6	280280-6
186.3	280277-7	280278-7	280279-7	280280-7
192.3	280277-8	280278-8	280279-8	280280-8
194.3	280277-9	280278-9	280279-9	280280-9
217.3	280277-10	280278-10	280279-10	280280-10
250.1	280277-11	280278-11	280279-11	280280-11

Wiring Table

CSPR

#	Color	Signal
1	White	Common
2	Red	Supply voltage (+)
3	Brown	PWM output
4	Green	Voltage output
-	Metallic	Shield (connect with input reference potential)

Linearity error	$-0.3 \text{ mm} \leq E_L \leq 0.3 \text{ mm}$
Repeatability error	$-25\mu\text{m} \leq E_R \leq 25\mu\text{m}$
Hysteresis error	$-25\mu\text{m} \leq E_H \leq 25\mu\text{m}$
Temperature Drift	$-10\mu\text{m}/^\circ\text{K} \leq E_{TPWM} \leq 10\mu\text{m}/^\circ\text{K}$ $-20\mu\text{m}/^\circ\text{K} \leq E_{TVoltage} \leq 20\mu\text{m}/^\circ\text{K}$
Current consumption	$20\text{mA} \leq I_S \leq 40\text{mA}$
Operating temperature	Operating temperature range: $-30^\circ\text{C} \leq AR \leq 85^\circ\text{C}$
Power supply voltage	$4.75\text{V} \leq V_S \leq 5.50\text{V}$
Output load	The load resistor for the PWM output should be connected to the sensors supply voltage with a value of: $120\Omega \leq R_L \leq 200\Omega$ The capacity to ground is defined to: $C_L \leq 50\text{pF}$ The load resistor for the voltage output should be connected to the sensors ground with a value of: $6\text{k}\Omega \leq R_L$ The capacity to ground is defined to: $C_L < 100\text{pF}$
Magnet	The sensor is designed for use with magnet part number 401842.
Package	CSPR IP65/67: IP65 Electronics IP67 Sensor

Initial tolerances for zero and gradient

The specified tolerances are:

	Zero tolerance	Gradient tolerance
PWM Output	$\pm 1.0 \text{ mm (at A)}$	$\pm 2.0\%$
Voltage Output	$\pm 1.0 \text{ mm (at B)}$	$\pm 0.5\%$



SENSORS
GROUP

Pioneers,
Innovators,
Leaders in
Magnetostrictive
Sensing

UNITED STATES
MTS Systems Corporation
Sensors Division
3001 Sheldon Drive
Cary, NC 27513
Tel: 800.761.9351
Ask for Commercial Sensors
Fax: 919.677.0200
www.mtscommercialsensors.com
commercial@mtssensors.com

GERMANY
MTS Systems Corporation
Sensors Technologie
Auf dem Schuffel 9, D-58513 Lüdenscheid, Germany
Postfach 8130 D-58489 Lüdenscheid, Germany
Tel: + 49.2351.95870
Fax: + 49.2351.56491
www.mtssensor.de

JAPAN
MTS Systems Corporation
Sensors Technology
Ushikubo Bldg.
737 Aihara-cho, Machida-shi
Tokyo 194-0211, Japan
Tel: + 81 (42) 775.3838
Fax: + 81 (42) 775.5512



